

재생 정보 기반 우연성 지향적 음악 추천에 관한 연구

하태현 · 이상원[†]

성균관대학교 인터랙션사이언스학과

A Study on Serendipity-Oriented Music Recommendation Based on Play Information

Taehyun Ha · Sangwon Lee

Department of Interaction Science, Sungkyunkwan University

With the recent interests with culture technologies, many studies for recommendation systems have been done. In this vein, various music recommendation systems have been developed. However, they have often focused on the technical aspects such as feature extraction and similarity comparison, and have not sufficiently addressed them in user-centered perspectives. For users' high satisfaction with recommended music items, it is necessary to study how the items are connected to the users' actual desires. For this, our study proposes a novel music recommendation method based on serendipity, which means the freshness users feel for their familiar items. The serendipity is measured through the comparison of users' past and recent listening tendencies. We utilize neural networks to apply these tendencies to the recommendation process and to extract the features of music items as MFCCs (Mel-frequency cepstral coefficients). In that the recommendation method is developed based on the characteristics of user behaviors, it is expected that user satisfaction for the recommended items can be actually increased.

Keywords: Music recommendation, Content-based, Serendipity, Neural networks

1. 서론

엔터테인먼트 산업은 해마다 꾸준한 성장세를 이뤄내고 있다. 1990년대 말부터 2000년대까지 전세계적으로 엔터테인먼트 관련 산업은 이미 2.2조 달러를 넘었으며, 매년 5%대의 성장률과 함께 2020년에는 6.1조 달러에 이를 것으로 전망되고 있다. 엔터테인먼트 산업은 방송, 출판, 게임, 스포츠 등을 포함하며, 음악 산업 역시 이 중 하나로 자리잡고 있다(Hull *et al.*, 2011). 제품 개발 및 정보검색 분야에서는 사용자 개인의 성향을 반영하여 사용자 개인에게 맞춤형 정보를 제공하고자 하는 연구들이 진행되고 있다(Im *et al.*, 2008; Kang and Bae, 2013). 또한, 최근 음악 검색 분야에서도 음악 산업 규모의 성장과 맞물려 점차 다양해지는 사용자의 요구사항에 대응하기 위하여 사용

자가 원하는 음악 아이템을 추천하기 위한 사용자 맞춤형 추천 시스템에 대한 연구가 진행되고 있다. 실례로, Mysounds, iTunes Genius, Last.fm, Pandora, Shazam와 같은 몇몇 사이트들은 음악 전문 추천 서비스를 제공하기 시작했으며 고객 맞춤화 서비스는 이들의 중요한 성공 요인으로 인식되고 있다(Ansari *et al.*, 2000; Bobadilla *et al.*, 2013).

음악 추천 시스템에 대한 기존의 연구는 음악 아이템의 특징을 추출하기 위해 파형 및 태그를 분석하거나, 추출된 특징들을 바탕으로 아이템들을 비교, 분류하는 것과 같이 주로 기술적 측면을 중심으로 진행되어 왔다(Celma, 2010; Pu *et al.*, 2012). Hotta and Hagiwara(2007), Celma and Serra(2008), Liu *et al.*(2010)은 사용자 정보를 음악 아이템 추천 과정에 함께 포함시켜, 사용자 개인의 음악적 취향을 보다 정확히 파악할 수 있

이 논문은 2015년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(NRF-2014R 1A 1A2054531).

[†] 연락처 : 이상원 교수, 110-745 서울시 종로구 성균관로 25-2 성균관대학교 인터랙션사이언스학과, Tel : 02-740-1865, Fax : 02-740-1856, E-mail : upcircle@skku.edu

2014년 9월 22일 접수; 2014년 11월 21일 수정본 접수; 2014년 12월 1일 게재 확정.

는 추천 시스템을 개발하였다. 그러나 이러한 연구들은 사용자 특징을 음악적 정보와의 유기적 관계 속에서 반영시키지 않고 성별, 나이, 지역과 같은 독립된 정보로서 다루었기 때문에, 추천 결과에 대한 해석이 어려웠다. 또한 하나의 음악 아이템에 대한 사용자들의 태도가 근본적으로 다를 수 밖에 없다는 음악의 주관적 성질을 고려해 볼 때, 지금까지 개발된 사용자 중심적 분석방법은 일정 부분 한계점을 가지고 있다(Celma, 2010; Song *et al.*, 2012; Tintarev and Masthoff, 2011).

좋은 추천 시스템 개발을 위해서는 사용자의 행동적 측면을 바탕으로 실질적인 선호도를 파악하고 이를 추천 아이템 선정 과정에 포함시켜야 한다(Beel *et al.*, 2013). 하지만 음악 아이템의 유사성에만 근거하여 새로운 음악 아이템을 추천해주는 것은 오히려 사용자의 만족도를 저하시킬 수 있다. 즉, 너무 빠른 아이템만이 추천될 경우에는 추천된 아이템에 대해 사용자가 흥미를 갖기 어려울 수 있다. 이와 관련하여, 몇몇 음악 추천 시스템은 우연성(serendipity)이라는 요소를 고려하였고 이를 통해 사용자가 예상치 못한 아이템을 추천함으로써 보다 높은 사용자 만족을 이끌어냈다(McNee *et al.*, 2006; Swearingen and Sinha, 2001). 이러한 우연성은 사용자의 아이템과 추천된 아이템의 비유사성에 근거한다. 즉, 너무 비슷한 음악을 추천하는 것이 아니라, 유사하지 않은 음악을 의도적으로 추천함으로써, 청취자에게 신선한 자극을 제공하는 것이다(Iaquinta *et al.*, 2008; Zhang *et al.*, 2012). 그러나 단순히 추천 과정에 비유사성을 바탕으로 한 우연성을 포함시키는 것은 사용자의 인지적/행동적 특징에 근거한 접근이 아니며, 여전히 사용자에게 실질적 만족을 주지 못할 가능성이 크다. 사용자의 실질적 만족으로 이어지는 아이템을 추천하기 위해서는 새로운 아이템에 대한 사용자의 선호 경향을 분석하고, 표면적 선호도와 실질적 선호도의 이론적 관계를 바탕으로 접근할 필요가 있는 것이다(Ward *et al.*, 2013).

본 연구는 사용자의 청취 행동에 대한 분석을 바탕으로 음악 아이템에 대한 실질적인 선호도를 이끌어 낼 수 있는 새로운 우연성을 정의하고, 이러한 우연성이 반영된 추천 방법을 개발하고자 한다. 제시 모델은 사용자의 음악 아이템 재생 기록을 바탕으로 과거와 최근의 청취 경향을 파악한다. 구체적으로, 음악 아이템의 특징은 MFCC(Mel-frequency cepstral coefficients)로 추출되며, 사용자의 재생 목록에 존재하는 음악 아이템들은 신경망 모델을 통해 사용자의 취향을 학습하는데 사용된다. 학습된 신경망을 통해, 데이터베이스 내 새로운 음악 아이템들에 대해 각각의 재생기대치를 부여하며, 다시 이 재생기대치 간 차이를 통해 우연성 점수를 정하게 된다. 최종적으로 우연성 점수가 높은 아이템이 추천 목록 상위에 배치되며, 사용자는 상위 아이템부터 순서대로 제공받는다.

2. 배경연구

본 장에서는 음악 추천 시스템에 관한 기존 연구를 살펴보고,

내용 기반 추천 시스템 방식의 한계점을 극복하기 위해 새로운 우연성의 개념을 제안하고 이를 정의한다. 또한 우연성 정도를 계산하기 위한 새로운 형태의 신경망 분석 기법을 설명한다.

2.1 음악 추천 시스템

음악 추천 시스템에 대한 연구는 크게 협업(CF : collaborative filtering), 내용 기반(CB : content-based) 방식으로 나눌 수 있다. 협업 방식은 비슷한 성향을 나타내는 그룹들을 비교하는 방식으로, 이는 다시 성향 조사의 기준에 따라 사용자 기반(user-based) 방식과 아이템 기반(item-based) 방식으로 구분 될 수 있다(Celma, 2010). <Figure 1>은 이와 같은 분류 기준을 나타낸다.

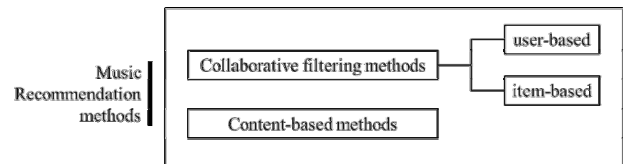


Figure 1. Music recommendation methods

사용자 기반 협업 방식은 추천 대상 사용자가 가진 음악 아이템들과 유사한 음악 아이템들을 가진 다른 사용자를 찾은 뒤 이를 참고하여 추천에 적용하는 방식이다. 사용자들 간 유사도 척도로는 주로 피어슨 상관계수, 코사인 유사도 등을 이용한다(Celma, 2010). 사용자 기반 협업 방식의 추천 시스템은 기본적으로 대상 사용자와 비교할 k명의 다른 사용자를 선정하고(1단계), 그들간의 유사도를 비교하여(2단계), 추천 아이템을 선정하는(3단계) 과정으로 진행된다. Breese *et al.*(1998), Chee *et al.*(2001), Kim *et al.*(2004) 등은 다양한 관점에서 사용자 기반 협업 방식을 제안하였고, 특히 Breese *et al.*(1998), Good *et al.*(1999), Sarwar *et al.*(2000) 등은 이러한 방식의 추천 시스템 간 성능을 비교하는 연구를 수행하였다. 그러나 분석 대상이 되는 사용자 집단의 규모가 커지고 평가 아이템의 개수가 증가함에 따라 기존 사용자 기반 방식의 적용에 있어 한계점이 드러났다. 이에 사용자의 입장이 아닌 아이템 관점에서 새로운 아이템을 추천해주는 아이템 기반 협업 방식의 연구가 등장하게 되었다(Sarwar *et al.*, 2001).

아이템 기반 협업 방식은 각 아이템의 관점에서 어떠한 사용자들이 해당 아이템을 선호하는지 알아보고, 이와 같은 사용자들이 공통적으로 선호하는 다른 아이템을 찾는 방식이다. 대표적으로, 아이템의 유사 정도에 따른 가중치 반영 방법(Sarwar *et al.*, 2001), 확률 모형을 이용한 방법(Li *et al.*, 2005) 등을 들 수 있는데, 아이템 기반 협업 방식의 특성 상 다수의 사용자가 선호하는 음악 아이템일수록 높은 추천 순위를 갖게 된다. 그러나 이 방식은 사용자들 간의 유사도를 반영하지 않으므로, 추천 아이템의 정확도가 떨어질 수 있다는 단점이 있다(Celma, 2010).

음악 아이템의 표면적인 선호도에 근거한 협업 기반 방식과 달리 내용 기반 방식은 음악이 가지고 있는 속성에 근거한다. 이 방식은 특정 사용자가 가지고 있는 음악 아이템의 특징(장르, 리듬, 음색 등)을 태그나 파형을 기준으로 파악하고 이와 유사한 음악을 추천한다(Celma, 2010). 일반적으로 내용 기반 추천 시스템은 크게 3개의 모듈로서, 콘텐츠를 분석하는 content analyzer, 사용자의 취향을 학습하는 profile learner, 사용자의 취향에 맞는 아이템을 추천해주는 filtering component로 구성된다. 또한 추천에 따른 사용자의 피드백을 받기 위해 선호/비선호(like/dislike), 순위(ratings), 평가 글(text comments) 등을 분석하여 활용하기도 한다(Lops et al., 2011).

Magno and Sable(2008)는 내용 기반 추천 시스템에서 사용된 여러 방법과 이를 바탕으로 음악 추천 서비스를 제공하고 있는 사이트들의 성능을 평가하였다. 연구에 따르면, 사람(전문가)에 의해 추천된 음악 아이템이 가장 높은 선호도를 나타냈으며, 웹 사이트 중에서는 Pandora와 Last.fm이 좋은 성능을 보이는 것으로 나타났다. 분석 방법 중에는 음색 모델(timbre model)을 바탕으로 음원을 추출한 뒤 추출된 음원의 특징 성분을 대상으로 GMM(Gaussian mixture model)과 EM(expectation maximization) 알고리즘을 적용한 분석 방법이 가장 좋은 성능을 보였다.

음악 추천 시스템(협업 기반 방식, 내용 기반 방식)은 사용자에게 아이템을 제시한 뒤, 결과에 대한 사용자의 선호도를 바탕으로 추천 성능을 평가한다. 각각의 방식은 고유의 장단점을 가지고 있다. 비슷한 사용자가 어떠한 아이템을 선호하는지 관찰하는 협업 방식은 사용자의 개별적 특징을 충분히 반영하지 못한다는 문제점을 가지고 있다. 또한, 내용 기반 방식은 수집된 아이템들의 크기에 따라 추천된 아이템이 특정 성향에 집중될 수 있다는 점(over specialize)과 참신성이 떨어질 수 있는(novelty problem) 한계점을 가지고 있다(Celma, 2010). 이러한 문제점을 해결하기 위한 혼합형 방식(hybrid methods)이 개발되기도 하였다(e.g., Bu et al., 2010; Passant and Raimond, 2008; Yoshii et al., 2006). 적합한 혼합형 방식은 내용 기반 방식과 협업 기반 방식의 장점을 동시에 살릴 수 있지만, 이와 함께 각 방식이 가지고 있는 단점들까지 반영될 수 있다는 문제점이 동시에 제기되기도 한다(Song et al., 2012).

한편, 사용자 중심의 분석 관점에서는 내용 기반 방식이 협업 기반 방식보다 합리적인 접근 방법일 수 있다. 이는 내용 기반 방식이 심리학적 음향 분석과 맥락적 내용에 대한 이해에 도움을 줄 수 있기 때문이다(Uitdenbogerd and van Schyndel, 2002). 하지만, 앞서 지적하였듯이 사용자의 음악 아이템을 바탕으로 연관성 높은 아이템만을 추천하는 것은 오히려 만족도를 저하시킬 수 있으며(Adomavicius and Tuzhilin, 2005; Beel et al., 2013; Herlocker et al., 2004; McNee et al., 2006), 사용자의 실질적 만족을 이끌어낼 수 없다. 이를 해결하기 위해선, 추천 시스템이 명백히 예측 가능하거나 반복해서 등장하는 유사한 음악을 추천 대상에서 제외하고 사용자가 익숙한 음악 아이템들

중에서 미처 인식하지 못한 새롭고 참신한 아이템을 추천해 주어야 한다. 즉, 우연성에 근거한 음악 아이템의 추천이 이루어져야 할 필요가 있는 것이다.

2.2 선호도와 우연성

앞서 제기되었던 내용 기반 음악 추천 시스템의 특정 성향 집중 문제와 참신성 문제를 해결하기 위해, 추천 과정 속에 우연성을 적용하고자 한 연구들이 진행되었다(Iaquinta et al., 2008; Zhang et al., 2012). 우연성 측정을 위해, 기존 연구들은 사용자의 재생 기록을 바탕으로 사용자가 기존에 가지고 있던 아이템과 추천된 아이템간 유사도를 비교하는 방식을 택하거나, 부분적인 협업 방식을 통해 다른 사용자의 음악 아이템을 참고하는 방법을 이용하였다. 하지만 이러한 방식은 추천된 아이템이 사용자의 실질적 선호도로 이어지기 위해 요구되는 사용자 행동 분석에 근거하지 않았다는 한계점을 가지고 있다. 우연성에 근거하여 추천된 아이템이 사용자에게 실질적인 만족감을 제공해주기 위해서는 단순히 유사성에 근거하거나 프로필이 비슷한 다른 사용자의 재생 목록을 참고하는 방식에서 벗어날 필요가 있으며 사용자의 실질적 선호도로 이어질 수 있는 우연성에 대한 새로운 접근이 이루어져야 한다.

Ward et al.(2013)에 따르면 사용자들은 완전히 새로운 것들 보다는 익숙한 것들을 선호하는 경향을 보이며, 이 익숙함이 음악 아이템을 선택하는데 가장 큰 영향을 미친다. 즉, 새로운 것을 원한다고 하더라도, 익숙한 것에 대한 무의식적 선호 현상이 나타나게 되는 것이다(Wilson, 2009). 이러한 결과를 바탕으로 사용자에게 실질적인 선호도를 이끌어 낼 수 있는 우연성은 완전히 새로운 것들이 아니라 익숙한 것들 사이에서 평소에 기대하지 않다가 생각지 않은 우연한 계기로 마주하게 되는 것에서 발생하는 것으로 생각해 볼 수 있다(Stumpf and Muscroft, 2011). 이는 선호도에 근거한 우연성으로서 음악에도 적용될 수 있으며, 음악 아이템의 재생 순서가 음악 추천에 있어서 중요한 분석 대상이 될 수 있음을 보여준다(Stumpf and Muscroft, 2011).

사용자 재생 목록에 존재하는 음악 아이템들은 재생 순서에 따라 흐름이라는 맥락적 정보를 가지게 된다(Stumpf and Muscroft, 2011). 사용자가 특정 음악 아이템들만을 대상으로 반복적인 청취를 하게 되면 내부적으로 습관적인 인지가 발생한다. 이러한 상황 속에서 무작위 재생은 사용자로 하여금 기존에 알고 있던 맥락적 정보와의 결합을 느슨하게 하고 재생 음악에 대한 새로운 관심을 갖도록 하여 결과적으로 높은 몰입도를 유도하게 된다(Leong et al., 2012). 이와 같은 낯설게하기(defamiliarization)는 우연성을 일으키는 자극으로 볼 수 있는데, 사용자가 특정 아이템들을 습관적으로 인지하기 시작했을 때 이와 같은 자극을 제공한다면 보다 높은 선호도를 이끌어 낼 수 있을 것이다.

본 연구에서 제시하는 추천 방식은 사용자의 재생 기록에

근거하여 사용자의 최근/과거 청취 경향을 파악한다. 이후 파악된 사용자의 청취 경향을 바탕으로 과거 청취 경향에 입각해서 보았을 때는 자주 들었을 법한 아이템이지만, 최근 청취 경향에 입각해서 보았을 때는 잘 듣지 않을 법한 음악을 추천해준다. 이것은 우연성을 고려한 추천 방식으로서, 사용자에게 익숙함과 동시에 새로움을 가져다 주고 사용자의 실질적 선호도로 이어질 수 있는 음악 아이템을 추천해주는 방식이 될 수 있다.

2.3 인공 신경망

내용 기반 음악 아이템 분석 시, 아이템의 특징을 추출하는 과정에서 음악 아이템의 제목, 장르, 가수 등의 태그 특징이나, MFCC와 같은 주파수 대역 별 특징 등의 고차원의 특징 벡터가 도출될 수 있다. 이 경우, 복잡한 데이터 학습과 예측에 널리 사용되는 인공 신경망(ANN : artificial neural network) 분석 기법을 고려해 볼 수 있다. 인공 신경망은 생물체의 신경네트워크를 모델링 하여 특정 문제를 해결할 수 있도록 만든 모델이다. 일반적으로 인공 신경망 모델은 현실에서 발생하는 문제 해결에 좋은 성능을 나타내며 이상치(noise)에 강하다는 장점이 있으나, 설명력이 부족하고 관련 분야에 대한 전문 지식이 요구된다는 특징을 가진다(Russell and Norvig, 2009). 인공 신경망을 이용한 분석은 화자 인식(speaker recognition)을 포함한 패턴 분류 및 인식 분야에서 널리 사용되어 왔다(Cheng and Titterton, 1994; Russell and Norvig, 2009).

Liu *et al.*(2010)는 음악 추천 시스템에 신경망 분석 방법을 적용한 연구를 진행하였다. 그들은 사용자 재생 목록에 존재하는 음악 아이템들을 오래 전 재생된 음악 아이템들과 최근에 재생된 음악 아이템들로 나누어, 두 개의 신경망을 통해 음악 아이템들의 특징을 학습하였다. 이 때 오래 전 재생된 음악 아이템들을 학습한 신경망은 long-term, 최근에 재생된 음악 아이템들을 학습한 신경망은 short-term 신경망으로 구분된다. 신경망 학습은 MFCC로 추출된 음악 아이템들의 특징을 입력값으로 하고, 사용자들이 음악 아이템들에게 부여한 선호도 점수를 출력값으로 하여 이뤄진다. 이렇게 학습된 두 개의 신경망을 바탕으로 새로운 음악 아이템에 대한 사용자의 선호도 점수를 예측하며, 각각의 예상 선호도 점수는 일정 비율로 결합되어 하나의 예상 선호도 점수로 환산된다.

연구자에 따르면, 하나의 신경망을 이용하지 않고 두 개의 신경망을 이용하여 학습과 예측을 실시하면 계산 과정 상에서의 복잡도를 줄일 수 있다. 그러나 해당 방식이 최근 청취 경향을 반영하는 것을 목적으로 한 기존 연구(Chen and Chen, 2005)를 바탕으로 진행되었다는 점을 고려하면, 계산 상의 복잡도를 줄이기 위한 방법에서 나아가 사용자의 청취 경향의 변화 양상을 분석하는 행동 분석 도구로도 활용될 수 있다. 본 연구에서 우리는 계산적 문제를 해결하기 위해 두 개의 신경망 분석 방법을 적용한 Liu *et al.*(2010)의 연구와는 다르게 최근과

과거의 사용자의 청취 경향 비교 분석을 하기 위해 해당 분석 방법을 이용하고자 한다. 또한 두 개의 학습된 신경망으로부터 도출된 선호도를 일정 비율로 합산하여 하나의 선호도로 활용한 기존의 방식과는 달리, 이들의 차이를 통해 새롭게 우연성을 발견하고 이를 추천 과정에 활용한다. 이와 같은 방식은 기존 방식과 분석 목적, 방법에 있어 차이점을 나타낸다 볼 수 있으며, 계산 복잡도를 해결하기 위한 방법에서 나아가 사용자의 행동 분석을 위한 방법으로 새롭게 확장시켰다는 데 의미가 있다.

3. 제시모델

제시하는 음악 추천 시스템은 크게 학습과 예측, 두 단계로 나누어진다. <Figure 2>는 이에 대한 전반적인 과정을 보여준다. 먼저 학습 단계에서는 사용자 정보 관리, 재생 기록 관리, 음악 아이템 특징 추출, 신경망 모듈을 통해 사용자가 가진 음악 아이템을 학습한다. 예측 단계에서는 데이터베이스 관리, 음악 아이템 특징 추출, 신경망, 우연성 계산 모듈을 통해 데이터베이스 내에 존재하는 모든 음악 아이템에 대해 우연성 점수를 할당한다. 이러한 과정은 앞서 사용자의 음악 아이템을 바탕으로 학습된 신경망 모델을 통해 이루어진다. 모든 아이템에 우연성 점수가 할당되면 높은 우연성을 가진 아이템 순으로 사용자에게 추천 아이템을 제공한다.

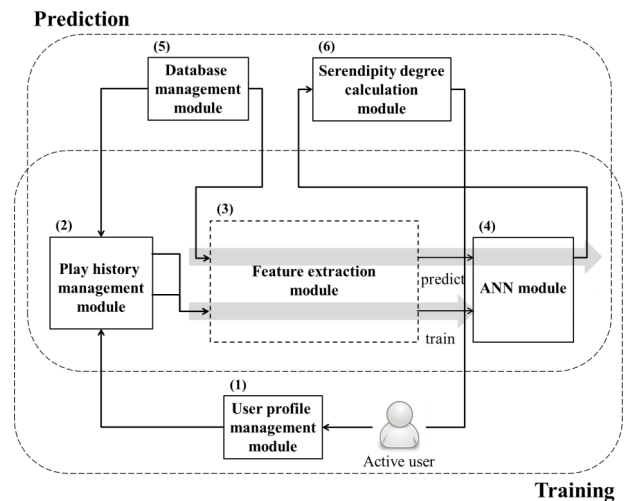


Figure 2. Overall structure of the recommendation system

3.1 사용자 정보 학습

사용자의 정보를 학습하는 과정은 사용자의 음악 아이템 분석에 사용될 만큼 충분한지 검사하는 ‘사용자 정보 관리 모듈’, 사용자의 음악 아이템을 과거와 최근 청취 음악으로 나누는 ‘재생기록 관리 모듈’, 음악 아이템의 특징을 추출하는 ‘특

징 추출 모듈', 추출된 특징을 바탕으로 사용자의 선호도를 학습하는 '신경망 모듈'로 구성된다. <Figure 2>의 (1)~(4)가 이와 관련된 요소들이며, 이들에 대한 세부적인 설명은 다음과 같다.

(1) 사용자의 음악 아이템 검사

음악 추천 시스템이 사용자의 음악적 취향을 학습하는 과정에 앞서, 사용자가 가지고 있는 음악 아이템의 개수가 학습에 사용되기에 충분한 양인지 먼저 검사할 필요가 있다. 이와 같은 과정은 <Figure 3>과 같이 나타내어질 수 있으며, 추천 시스템 내 사용자 정보 관리 모듈에서 진행된다. 만일 사용자의 음악 아이템의 개수가 분석에 충분치 않을 경우에는 문제가 발생할 수 있다(cold-start problem). 본 추천 시스템에서는 이와 같은 문제를 해결하기 위해서, 충분한 재생 기록이 확보되지 않은 사용자와 유사한 재생 기록을 가지고 있는 다른 사용자의 재생 목록을 참고하는 부분적 협업 기반 방식을 이용한다(Liu et al., 2010).

(2) 사용자의 재생 기록 내 음악 아이템 분할

다음으로 사용자의 재생 기록을 대상으로 과거 재생 기록과 최근 재생 기록을 나눈다. 이와 같은 작업은 재생 기록 관리 모듈을 통해 이뤄지는데, 사용자가 소유한 음악 아이템의 정보는 데이터베이스 관리 모듈로부터 제공받게 된다. 재생 기록 관리 모듈은 현 시점과 과거의 특정 시점 사이에 재생된 음악 아이템을 최근의 것으로, 그보다 더 먼저 재생된 음악 아이템을 과거의 것으로 설정한다. 최근과 과거의 기준이 되는 과거의 시점은 사용자의 선호도에 따라 조정될 수 있다. <Figure 4>는 이와 같은 과정을 나타내고 있다.

이와 같이 사용자의 재생 기록을 두 부분으로 나누는 이유는 우연성의 개념에 입각해 새로운 음악 아이템을 추천하기 위함이다. 본 연구에서 우연성은 사용자가 소유한 음악 아이템과 완전히 다른 것에서 발생하는 것이 아니라, 사용자 내부의 음악적 선호도에 근거한 것이다. 따라서, 우연성을 반영하기 위해서는 과거에 자주 들었을 것으로 예상되는 음악이지만 최근에는 자주 듣지 않을 것으로 예상되는 새로운 음악을 추천 하여야 하고, 이에 사용자의 재생 기록을 과거와 최근 기록으로 나누어 사용자의 음악 선호도를 학습시킬 필요가 있다.

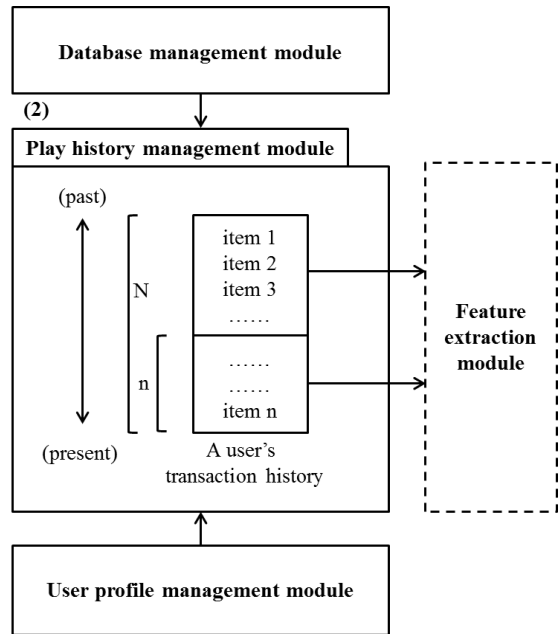


Figure 4. Play history management module

(3) 음악 아이템 특징 추출

사용자의 재생 기록이 과거와 최근으로 분리되면, 각각의 재생 기록 내 존재하는 음악 아이템들은 특징 추출 모듈을 거쳐 최종적으로 2개의 특징 벡터로서 표현된다. <Figure 5>는 음악 아이템 특징 추출에 관한 전반적인 과정을 나타내고 있다. 음악 아이템 추출 모듈은 음악 아이템의 특징 추출을 위해 음악 신호를 대상으로 12개의 MFCC와 3개의 Formant를 추출한다. 이때 모든 음악 아이템의 sampling rate는 16kHz로 설정된다. MFCC는 여러 MFC(Mel-frequency cepstrum)를 모아놓은 계수들을 의미하며, 비선형 파형을 윈도우 과정과 FFT(fast Fourier transform)을 통해 변환한 뒤, Mel filter bank를 거쳐 로그 파워 스펙트럼으로 변환하고 여기에 DCT(direct cosine transform)를 적용함으로써 얻을 수 있다. MFCC를 이용한 방법은 음악 아이템 추천 연구 분야에서 아이템의 특징 파악을 위해 주로 사용되어 왔다(Celma, 2010). 본 모델의 MFCC 추출 과정은 음악 아이템의 파형을 20ms 프레임으로 나누어 1/2 프레임 사이즈가 오버랩 되도록 추출한다. 이러한 과정을 거쳐 음악 파형은 12개의 MFCC로 표현된다(Liu et al., 2010). Formant는 음성 인

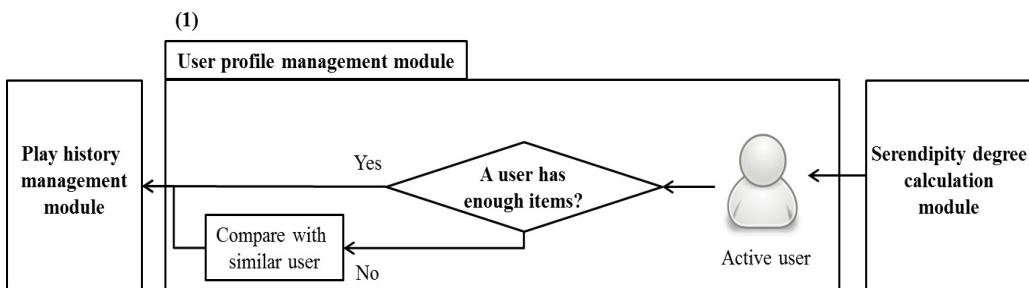


Figure 3. User profile management module

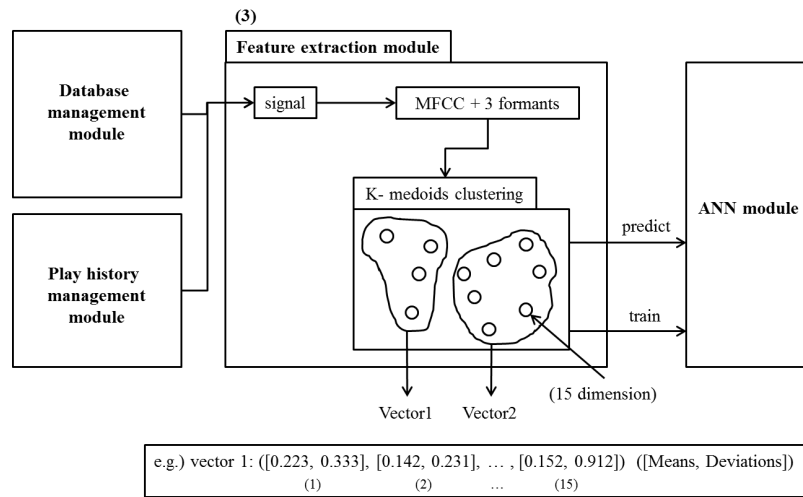


Figure 5. Feature extraction module

식에서 주요한 요소이며, 사람의 목소리 마다 다른 형태의 분포를 갖는다(Barrichelo *et al.*, 2001). 특징 벡터의 차원을 줄이기 위하여, 본 모델에서는 첫 번째(F1)와 두 번째(F2), 그리고 세 번째(F3) Formant만 사용하는데, 이들 Formant는 소리(sound source)를 구분하는 데에 보다 유용하게 사용될 수 있다.

여러 개의 15차원의 특징 벡터(3개의 formants와 12개의 MFCC)를 신경망 모델에 직접적으로 적용하는 것은 과도한 계산량을 발생시키기 때문에 군집화 방법을 거쳐 복잡성을 낮춘다. 대표적인 군집화 방법에는 k-medoids 방법과 k-means 방법이 있는데, k-medoids 방법이 k-means 방법에 비해 이상치(outlier)에 덜 민감하다고 알려져 있다(Han *et al.*, 2006). 15차원의 특징 벡터 집합은 k-medoids 군집화 방법(k = 2)을 통해 2개의 대표 특징으로 군집화되며, 군집 내 데이터의 각 차원의 평균과 분산으로 표현된다(Liu *et al.*, 2010). 일반적인 음악 추천 시스템

과 마찬가지로, 본 추천 시스템도 데이터베이스 내 음악 아이템들을 특징 추출이 끝난 상태로 저장하며 하나의 정보로서 활용한다. 따라서 위와 같은 특징 추출 과정은 시스템 전반에 걸쳐 매번 반복되지는 않는다.

(4) 신경망 모델 학습

추출된 음악 아이템의 특징과 해당 음악 아이템의 재생 횟수를 바탕으로 신경망 모델에서는 사용자의 선호도를 나타내는 신경망 모델을 학습하게 된다. <Figure 6>은 신경망 모델 학습에 관한 전반적인 과정을 나타내고 있다. 신경망 모델은 학습에 사용되는 음악 아이템의 파일 속성에 남아있는 액세스한 날짜를 기준으로 오래 전 액세스된 파일은 Long-term 신경망에, 최근에 액세스된 파일은 Short-term 신경망에 할당한다. 이후 각각의 신경망들은 할당된 음악 아이템들의 특징 벡터와

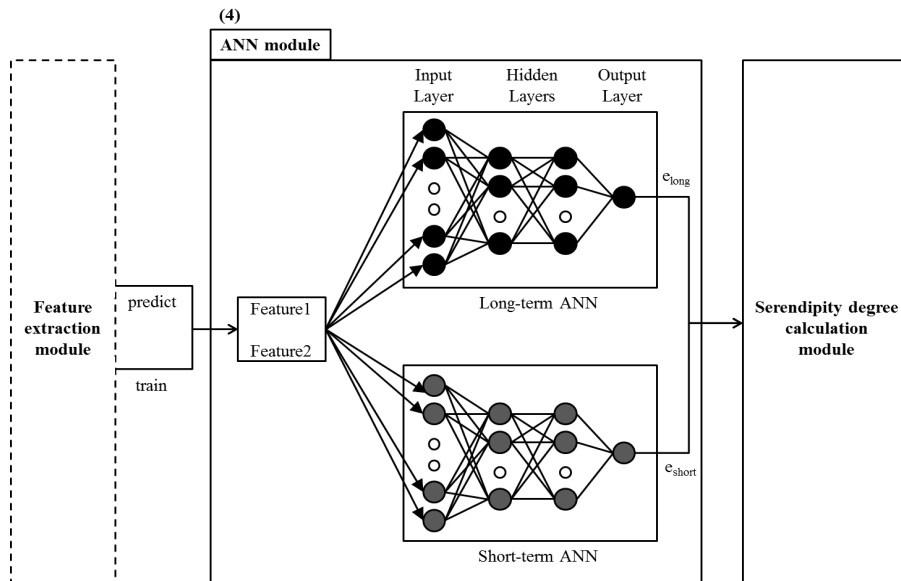


Figure 6. ANN module

재생 횟수를 입력값과 출력값으로 하여 학습을 실시한다. 과거와 최근 음악 아이템을 구분하는 시점은 기본적으로 테스트와 피드백을 통한 경험적 방법을 바탕으로 결정되며 사용자의 피드백에 따라 조정될 수 있다. 재생 횟수는 사용자가 특정 음악에 대한 갖게 되는 선호도와 연결시킬 수 있는데, 이는 일반적으로 선호도가 높은 아이템일수록 재생 횟수가 많기 때문이다(Kordumova *et al.*, 2010).

$$Y = \frac{2\alpha}{1 + e^{bx}} - \alpha \quad (1)$$

신경망 학습 과정에서 소요되는 시간을 단축시키기 위해 Guyon(1991)이 제시한 활성화 함수를 사용한다(식 (1) 참조). 식 (1)에서 a, b는 상수를 나타내며, x는 신경망 학습과정에서 사용하게 될 특징 벡터(X)와 가중치(ω)를 곱한 값에 bias(θ)를 더한 값을 의미한다($x = \omega X + \theta$). 특징 벡터를 통해 도출된 출력 값 Y는 연결된 다음 노드로 값을 전달해주는 역할을 하며, 신경망 모델의 오류를 수정하는 과정(back propagation)의 피드백 값으로 사용된다. 결과적으로, 학습을 통해 형성된 두 신경망은 각각 사용자의 과거/최근 음악 선호도를 보여주며, 학습된 신경망 모델은 사용자의 과거/최근 음악 취향 경향에 근거하여 새로운 음악 아이템에 대한 재생 기대치를 예측한다.

3.2 사용자 선호 아이템 예측

사용자의 음악 아이템 선호도에 대한 학습이 끝나면 데이터베이스 내 모든 음악 아이템들은 사용자의 선호도에 입각하여 우연성을 할당 받는다. 이러한 과정은 음악 아이템에 대한 정보를 제공하는 ‘데이터베이스 모듈’, 신경망 모듈을 통한 재생 기대치를 바탕으로 우연성 점수를 계산하는 ‘우연성 계산 모듈’을 통해 이루어진다. <Figure 2>의 구성요소 (5), (6)은 이와 관련한 부분을 나타내고 있으며, 이에 대한 구체적인 설명은 다음과 같다.

(1) 데이터베이스 내 음악 아이템 정보 제공

음악 추천 시스템에서 이뤄지는 모든 과정에서 사용되는 음악 아이템들은 하나의 데이터베이스 내에서 관리된다. 데이터

베이스 내 존재하는 모든 음악 아이템들은 기본적으로 특징 추출 과정을 거쳐 앞서 설명한 15차원의 특징 벡터 정보와 함께 존재한다. 앞서 언급한 바와 같이, 이러한 특징 추출은 하나의 데이터베이스 내 음악 아이템들만을 대상으로 하는 일회성의 작업으로 볼 수 있다. 다만, 데이터베이스에 새로운 음악 아이템이 추가될 때에는 그 아이템에 대한 특징 추출이 추가적으로 요구된다.

데이터베이스 관리 모듈은 시스템이 특정 사용자에 대해 음악을 추천하는 과정에서 음악 아이템에 대한 정보를 제공하는 역할을 한다. 데이터베이스 내 모든 음악 아이템은 각 사용자의 선호도를 나타내는 신경망 모듈을 통해 예상 재생 횟수를 부여 받고, 이를 다시 우연성 점수 계산 모듈에 보내 우연성 점수로 환산한다. 이러한 과정은 사용자마다 다르게 나타나는데, 이는 각 사용자의 신경망 모델 형태가 다르고 재생 목록 내 음악 아이템들 역시 다르기 때문이다. 또한, 재생 목록이 가지는 변동성으로 인해 사용자의 갱신된 선호도에 근거한 우연성 점수가 바뀌게 된다. 결국, 이러한 과정을 통해 얻어진 정보는 해당 사용자에게만 유효한 고유성(uniqueness)을 갖게 된다.

(2) 신경망 예측 및 우연성 점수 할당

마지막 과정으로, 사용자가 가진 음악 아이템에 근거한 신경망 모델을 통해 데이터베이스 내 음악 아이템의 과거/최근 선호도 기반 재생 기대치를 구한다. 이 수치를 바탕으로 우연성 점수 계산 모듈은 Long-term 신경망에서 도출된 예상 재생 횟수(e_{long})와 Short-term 신경망에서 도출된 예상 재생 횟수(e_{short})간의 차이로 해당 아이템에 대한 우연성 점수($s_i = e_{long} - e_{short}$)를 계산한다. 이 수치가 높을수록 우연성이 높을 것으로 예상되는 아이템으로 볼 수 있다. <Figure 7>은 학습된 신경망 모델을 통해 아이템들의 우연성을 계산하는 과정을 나타내고 있다. 이와 같이 우연성 점수를 두 값의 차이로서 표현하는 것은, 과거에 자주 들을 법한 아이템이고 최근에는 잘 듣지 않는 아이템일 수록 우연성이 클 것이라는 본 추천 시스템의 설정을 반영하기 위함이다.

최종적으로, 데이터베이스 내 저장된 음악 아이템은 이러한 과정을 통해 해당 사용자의 선호도에 입각한 우연성 점수를 할당 받는다. 우연성 점수 할당 과정이 끝나면, 데이터베이스 내 음악 아이템은 우연성 점수에 따라 내림차순으로 정렬되

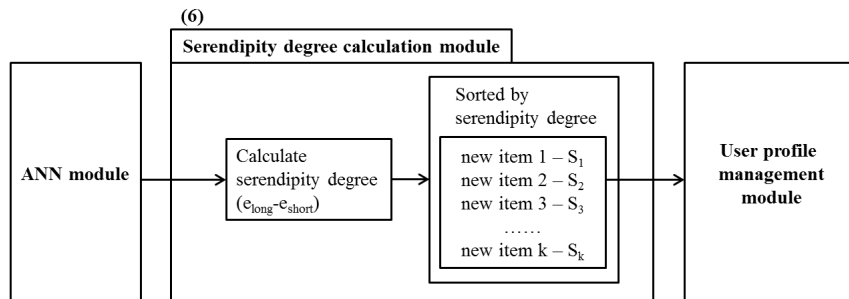


Figure 7. Serendipity degree calculation module

고, 우연성이 높을 것으로 예상되는 상위 n 개의 아이템이 해당 사용자에게 추천된다.

4. 토의 및 결론

본 연구는 기존의 내용 기반 음악 추천 시스템이 가지고 있는 참신성 문제를 해결하고 사용자의 실질적 선호도와 연결되는 음악 아이템을 추천하기 위한 새로운 방식의 우연성 기반 추천 방식을 제안하였다. 제시 모델은 크게 여섯 단계(모듈)에 걸쳐 새로운 음악 아이템을 선정하고 사용자의 재생 기록을 바탕으로 우연성이 높은 아이템을 순서대로 추천한다.

최근의 음악 추천 시스템은 사용자가 가진 음악 아이템의 일반적 특징을 바탕으로 이와 유사한 음악 아이템을 추천하는 방식에서 벗어나고 있다. 몇몇 연구들이 음악 추천에 있어 비유사성을 고려하였으며 이를 우연성을 추구하는 방식으로 풀어내고 있다. 이러한 흐름 속에서, 우리는 보다 본질적인 사용자의 행동 패턴에 근거한 새로운 개념의 우연성을 정의하고 이를 음악 아이템 추천 과정에 도입하였다. 제안하는 방식은 기존의 비유사성 기반 연구와 달리, 사용자의 청취 경향을 과거와 최근으로 나누어 상대적 관점에서 우연성을 설명하였고 이를 통해 익숙함 속에 신선함이라는 개념을 갖는 음악 아이템을 추천하고자 하였다. 이는 음악 아이템에 대한 사용자의 실질적 선호도와 보다 잘 연결될 수 있는 추천 방식을 제안하였다는 점에서 의미가 있다.

추후 연구는 본 연구에서 제시한 음악 추천 방식의 타당성과 실효성을 검증하는 데에 초점을 맞출 필요가 있다. 기본적으로 사용자들을 대상으로 하는 실질적 실험을 통해 추천 방식에 대한 타당성을 확보하고, 기존의 다른 방식과의 차별성과 우수성을 검토하여야 한다. 또한, 우연성을 파악하기 위해 사용자의 최근/과거 재생 기록을 분류하는 기준에 대한 이론적 근거가 아직은 명확하지 않은 상황 속에서, 본 연구가 언급한 사용자의 만족도를 바탕으로 한 피드백 방식은 내재적으로 한계점을 가질 수밖에 없다. 향후 연구에서는 이에 대한 보다 충분한 이론적, 실험적 근거 마련이 필요할 것으로 보인다. 나아가, 본 추천 방식의 타당성이 확보된다면 이를 또 다른 새로운 방식의 기본으로 활용할 수 있을 것이다. 각 사용자의 청취 경향에 따라 기존 추천 방식을 부분적으로 이용할 수 있고 이를 본 연구에서 제안한 추천 방식과 혼합하여 새로운 방식으로 발전시킬 수도 있다. 또한, 다른 방식의 음악 아이템 특징 추출 방식을 적용함으로써 새로운 추천 방식의 방향을 설정할 수 있을 것이다.

참고문헌

Adomavicius, G. and Tuzhilin, A. (2005), Toward the next generation of recommender systems : A survey of the state-of-the-art and possible

- extensions, *Knowledge and Data Engineering, IEEE Transactions on*, 17(6), 734-749.
- Ansari, A., Essegai, S., and Kohli, R. (2000), Internet recommendation systems, *Journal of Marketing research*, 37(3), 363-375.
- Barrichelo, V. M. O., Heuer, R. J., Dean, C. M., and Sataloff, R. T. (2001), Comparison of singer's formant, speaker's ring, and LTA spectrum among classical singers and untrained normal speakers, *Journal of voice*, 15(3), 344-350.
- Beel, J., Langer, S., Genzmehr, M., Gipp, B., Breiteringer, C., and Nürnberger, A. (2013), Research paper recommender system evaluation : a quantitative literature survey, In *Proceedings of the International Workshop on Reproducibility and Replication in Recommender Systems Evaluation*, 15-22.
- Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A. (2013), Recommender systems survey, *Knowledge-Based Systems*, 46, 109-132.
- Breese, J. S., Heckerman, D., and Kadie, C. (1998), Empirical analysis of predictive algorithms for collaborative filtering, In *Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence*, 43-52.
- Bu, J., Tan, S., Chen, C., Wang, C., Wu, H., Zhang, L., and He, X. (2010), Music recommendation by unified hypergraph : combining social media information and music content, In *Proceedings of the international conference on Multimedia*, 391-400.
- Celma, O. (2010), Music recommendation and discovery : The long tail, long fail, and long play in the digital music space : Springer.
- Celma, O. and Serra, X. (2008), FOAFing the music : Bridging the semantic gap in music recommendation, *Web Semantics : Science, Services and Agents on the World Wide Web*, 6(4), 250-256.
- Chee, S. H. S., Han, J., and Wang, K. (2001), Rectree : An efficient collaborative filtering method, In *Data Warehousing and Knowledge Discovery*, 141-151.
- Chen, H. C. and Chen, A. L. (2005), A music recommendation system based on music and user grouping, *Journal of Intelligent Information Systems*, 24(2/3), 113-132.
- Cheng, B. and Titterton, D. M. (1994), Neural networks : A review from a statistical perspective, *Statistical science*, 2-30.
- Good, N., Schafer, J. B., Konstan, J. A., Borchers, A. I., Sarwar, B., Herlocker, J., and Riedl, J. (1999), *Combining collaborative filtering with personal agents for better recommendations*, In *AAAI/IAAI*, 439-446.
- Guyon, I. (1991), Applications of neural networks to character recognition, *International Journal of Pattern Recognition and Artificial Intelligence*, 5(01n02), 353-382.
- Han, J., Kamber, M., and Pei, J. (2006), *Data mining : concepts and techniques* : Morgan kaufmann.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T. (2004), Evaluating collaborative filtering recommender systems, *ACM Transactions on Information Systems (TOIS)*, 22(1), 5-53.
- Hotta, H. and Hagiwara, M. (2007), *User profiling system using social networks for recommendation*, In *Proceedings of International Symposium on Advanced Intelligent Systems*, 207-274.
- Hull, G. P., Hutchison, T. W., and Strasser, R. (2011), *The Music Business and Recording Industry : Delivering Music in the 21st Century* : Taylor and Francis.
- Iaquinta, L., De Gemmis, M., Lops, P., Semeraro, G., Filannino, M., and Molino, P. (2008), Introducing serendipity in a content-based recommender system, In *Hybrid Intelligent Systems, HIS Eighth International Conference on*, 168-173.
- Im, Y., Jung, E. S., and Park, S. (2008), Development of an ergonomic product development process reflecting quantified customer prefer-

- ence, *Journal of the Korean Institute of Industrial Engineers*, **34**(1), 66-78.
- Kang, Y. and Bae, J. (2013), Customized web search rank provision, *Journal of the Korean Institute of Industrial Engineers*, **39**(2), 119-128.
- Kim, B. M., Li, Q., Kim, J. W., and Kim, J. (2004), A new collaborative recommender system addressing three problems, In *PRICAI : Trends in Artificial Intelligence*, 495-504.
- Kordumova, S., Kostadinovska, I., Barbieri, M., Pronk, V., and Korst, J. (2010), *Personalized implicit learning in a music recommender system*, In *18th International Conference, UMAP*, 351-362.
- Leong, T. W., Vetere, F., and Howard, S. (2012), Experiencing coincidence during digital music listening, *ACM Transactions on Computer-Human Interaction (TOCHI)*, **19**(1), 6.
- Li, Q., Myaeng, S. H., Guan, D. H., and Kim, B. M. (2005), A probabilistic model for music recommendation considering audio features, In *Information retrieval technology*, 72-83.
- Liu, N. H., Hsieh, S. J., and Tsai, C. F. (2010), An intelligent music playlist generator based on the time parameter with artificial neural networks, *Expert Systems with Applications*, **37**(4), 2815-2825.
- Lops, P., de Gemmis, M., and Semeraro, G. (2011), Content-based recommender systems: State of the art and trends, *Recommender Systems Handbook*, 73-105.
- Magno, T. and Sable, C. (2008), A Comparison of Signal Based Music Recommendation to Genre Labels, Collaborative Filtering, Musicological Analysis, Human Recommendation and Random Baseline, In *ISMIR*, 161-166.
- McNee, S. M., Riedl, J., and Konstan, J. A. (2006), Being accurate is not enough : how accuracy metrics have hurt recommender systems, In *CHI extended abstracts on Human factors in computing systems*, 1097-1101.
- Passant, A. and Raimond, Y. (2008), Combining Social Music and Semantic Web for music-related recommender systems, In *The 7th International Semantic Web Conference*, 19.
- Pu, P., Chen, L., and Hu, R. (2012), Evaluating recommender systems from the user's perspective : survey of the state of the art, *User Modeling and User-Adapted Interaction*, **22**(4-5), 317-355.
- Russell, S. J. and Norvig, P. (2009), *Artificial intelligence : a modern approach*, Prentice Hall.
- Sarwar, B., Karypis, G., Konstan, J. A., and Riedl, J. (2000), Application of dimensionality reduction in recommender system-a case study : DTIC Document.
- Sarwar, B., Karypis, G., Konstan, J. A., and Riedl, J. (2001), Item-based collaborative filtering recommendation algorithms, In *Proceedings of the 10th international conference on World Wide Web*, 285-295.
- Song, Y., Dixon, S., and Pearce, M. (2012), A survey of music recommendation systems and future perspectives, In *9th international symposium on computer music modelling and retrieval (CMMR 2012)*, 19-22.
- Stumpf, S. and Muscroft, S. (2011), When users generate music playlists : When words leave off, music begins? In *Multimedia and Expo (ICME), 2011 IEEE International Conference on*, 1-6.
- Swearingen, K. and Sinha, R. (2001), Beyond algorithms : An HCI perspective on recommender systems, In *ACM SIGIR 2001 Workshop on Recommender Systems*, 393-408.
- Tintarev, N. and Masthoff, J. (2011), Designing and evaluating explanations for recommender systems, *Recommender Systems Handbook*, 479-510.
- Uitdenbogerd, A. L. and van Schyndel, R. G. (2002), A Review of Factors Affecting Music Recommender Success, In *ISMIR*, **2**, 204-208.
- Ward, M. K., Goodman, J. K., and Irwin, J. R. (2013), The same old song : The power of familiarity in music choice, *Marketing Letters*, 1-11.
- Wilson, T. D. (2009), Know thyself, *Perspectives on Psychological Science*, **4**(4), 384-389.
- Yoshii, K., Goto, M., Komatani, K., Ogata, T., and Okuno, H. G. (2006), Hybrid Collaborative and Content-based Music Recommendation Using Probabilistic Model with Latent User Preferences, In *ISMIR*, **6**, 7th.
- Zhang, Y. C., Séaghdha, D. Ó., Quercia, D., and Jambor, T. (2012), Auralist : introducing serendipity into music recommendation, In *Proceedings of the fifth ACM international conference on Web search and data mining*, 13-22.