

시간 가중치와 가변형 K -means 기법을 이용한 개인화된 음악 추천 시스템

A Personalized Music Recommendation System with a Time-weighted Clustering

김재광 · 윤태복 · 김동문 · 이지형

Jaekwang Kim, Taebok Yoon, Dongmoon Kim and Jee-Hyong Lee

성균관대학교 전자전기컴퓨터공학과

요 약

근래 들어 개인 적응형 서비스에 대한 관심이 높아지고 있으나 아직 음악에 관련된 서비스는 보편화되어 있지 않다. 그 이유는 음악의 관련 정보를 분석하는 것이 텍스트 기반의 자료에 비해 어렵기 때문이다. 이에 본 논문은 사용자가 선택했던 음악을 분석해서 사용자의 성향을 파악하고 그와 유사한 음악을 추천해주는 시스템을 제안한다. 음악의 속성을 추출하는 방법으로 음파 분석 기법을 사용한다. 음파에서 세 가지의 수치화된 속성을 추출하여 이를 특성 공간에 나타낸다. 이 때 사용자가 선택한 음악이 많이 모여 있는 군집을 분석한다면, 사용자의 취향을 파악할 수 있다. 하지만 몇 개의 군집이 형성될 것인지를 예측하기란 쉽지 않다. 이를 해결하기 위하여 군집의 수를 상황에 따라 유동적으로 변경할 수 있는 가변형 K -means 기법을 제시한다. 이 기법은 군집의 직경 크기를 제한하여, 일정치 이상일 때 군집의 수를 늘리는 방법으로 데이터의 범위를 알고 있을 때 매우 효율적으로 적용할 수 있다. 이 방법을 이용하여 군집의 중심을 찾고 이와 가까운 음악을 추천한다. 또한 사용자의 성향은 꾸준히 변화하므로 본 논문은 사용자가 근래에 선택한 음악의 반영 비율을 높이고자 무게의 개념을 이용한 시간 가중치 기법을 적용하였다. 그리고 음악의 발매 시기도 고려하여 음악을 추천하는 시스템을 제안한다. 제안 방법의 검증은 위하여 100개의 음악 조각을 통한 실험적 검증을 하였으며 그 결과 제안 방법이 효과적인 것을 보인다.

키워드 : 음악 추천시스템, 시간 가중치, 가변형 K -means 군집화 기법

Abstract

Recently, personalized-adaptive services became the center of interest in the world. However the services about music are not widely diffused out. That is because the analyzing of music information is more difficult than analyzing of text information. In this paper, we propose a music recommendation system which provides personalized services. The system keeps a user's listening list and analyzes it to select pieces of music similar to the user's preference. For analysis, the system extracts properties from the sound wave of music and the time when the user listens to music. Based on the properties, a piece of music is mapped into a point in the property space and the time is converted into the weight of the point. At this time, if we select and analyze the group which is selected by user frequently, we can understand user's taste. However, it is not easy to predict how many groups are formed. To solve this problem, we apply the K -means clustering algorithm to the weighted points. We modified the K -means algorithm so that the number of clusters is dynamically changed. This manner limits a diameter so that we can apply this algorithm effectively when we know the range of data. By this algorithm we can find the center of each group and recommend the similar music with the group. We also consider the time when music is released. When recommending, the system selects pieces of music which is close to and released contemporarily with the user's preference. We perform experiments with one hundred pieces of music. The result shows that our proposed algorithm is effective.

Key Words : Music recommendation, Time-weighted Clustering, Improved K -means algorithm

1. 서 론

많은 사람들이 웹사이트를 통해 쉽게 음악을 다운로드

접수일자 : 2008년 10월 2일

완료일자 : 2009년 8월 1일

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업의 연구 결과입니다. 연구비 지원에 감사드립니다(No.2009-0075109).

받고 있다. 하지만 개인화된 추천 서비스를 제공하고 있는 사이트는 극히 드물다. 일반적으로 추천시스템은 크게 내용 기반(content-based)과 협업(collaborative) 추천 방식의 두 가지 방식을 사용한다. 내용 기반(content-based) 추천 방식은 사용자가 과거에 선호했던 내용을 분석하여 사용자의 취향을 판단하는 방식이며, 협업(collaborative) 추천 방식은 비슷한 취향을 가지는 사용자들 그룹화 하여 추천하는 방식이다. 하지만 후자 방식의 시스템을 구축하려면 사용자의 자료를 수집한 데까지 많은 시간이 걸리며, 개개인의 취

향을 알 수 없게 된다. 또한 소수의 사람이 선택한 음악은 추천을 받지 못할 수도 있다. 따라서 본 논문에서는 보다 개인화된 추천 서비스를 제공하기 위하여 전자 방식의 추천 방법을 제안한다.

일반적으로, 사용자의 취향은 시간에 따라 변한다. 그러므로 사용자가 음악을 청취했던 시기에 대해서 주목을 해야 할 필요가 있다. 그러나 대부분의 추천 시스템이나 많이 사용되는 기법들은 이 문제에 대해 다루지 않는 경우가 많다. 또한 음악이 발매된 시기 또한 사용자의 선호도에 중요한 부분에 속한다. 일반적으로, 젊은 층일수록 근래에 나온 음악을 선호하고 중장년층에서는 오래 전에 발매된 음악을 선호한다. 이를 인지한 몇몇의 음악 포털 사이트들은 70년대, 80년대, 90년대, 2000년대 별로 시기를 나누어 인기 순위를 제공하고 있다. 또한 이 서비스는 사용자들의 좋은 반응을 얻고 있다. 따라서 사용자가 청취한 음악들에 대한 요소 중 시대적 요소 또한 중요하게 다뤄야 된다는 것을 인식할 수 있다. 따라서 시대적 요소를 사용하기 위해서는 다른 방법의 접근이 필요하다. 본 논문에서는 사용자의 리스트를 통해 선호하는 음악이 많은 시기를 분석하고 이를 추천한다.

개인화된 서비스를 구축하기 위해서는 많은 문제점이 따르지만 일반적으로 다음과 같은 세 가지 문제점이 거론된다. 속성을 어떻게 분석할 것인지, 어떻게 사용자의 선호도를 분석해낼 것인지 그리고 어떤 것을 추천해줄 것인지가 그 문제점이 된다. 본 논문은 상기의 세 가지 문제점에 대한 해결안을 하나씩 제시한다. 첫 번째 문제의 해결방법은 선호도 분석은 음악을 구성하는 음파를 사용한다. 음파를 분석하는 방법으로는 STFT (Shortest Time Fourier Form) 기법을 이용하며 이를 통해 음파를 수치화된 정보로 추출한다. 두 번째 문제점인 사용자의 선호도를 분석하는 방법은 사용자의 리스트를 통해서 분석한다. 사용자가 음악을 듣거나 다운로드 했을 경우 이를 사용자의 리스트에 저장한다. 그리고 이를 분석하여 사용자의 선호도를 추론한다. 또한 본 논문은 가변형 K -means 알고리즘을 제안한다. 기본적인 K -means 알고리즘은 숫자 K 를 입력 받아 K 개의 군집을 형성하는 기법이다. 사용자가 선호하는 음악의 군집만큼 K 를 입력하면 되지만 이를 예측하는 것은 쉽지 않다. 따라서 상황에 맞게 군집의 수를 예측하고 조절하는 알고리즘이 필요하다. 이에 직경의 제한을 둬으로써 군집의 숫자를 유동적으로 조절하는 가변형 K -means 알고리즘을 제시한다. 특정 군집의 직경이 일정치 이상일 때, 군집의 수를 늘리는 방법을 사용한다. 이 때 나타나는 군집의 중심이 사용자의 선호도가 된다. 구해진 군집의 중심과 각각의 음악들 간의 유클리디언 거리를 측정하여 이를 비교한다. 만약 중심과 가까이 위치할수록 이는 사용자가 보다 선호하는 음악이므로 이를 추천하게 된다. 또한 군집을 이루는 원소, 즉 사용자의 리스트가 많을 때 해당 군집에 더 큰 비중을 둬으로써 적절한 추천이 이루어지도록 한다.

2. 관련 연구

본 절에서는 본 연구와 관련하여 두 가지 분야의 관련 연구 기술을 통해 본 연구의 필요성 및 우수성을 기술한다. 첫째는 음악 추천 분야의 관련 연구와의 비교이다. 둘째는 제안 방법에서 사용한 가변형 K -means 방법과 비교 가능한 기존의 알고리즘들과의 비교이다.

2.1 음악 추천 관련 연구

음악 추천에 대한 연구는 근래 들어 더욱 활발하게 진행되고 있으며, 그 방법은 크게 두 가지로 나누어 볼 수 있다. 우선 내용 기반 추천 방식의 연구를 소개한다. P. Cano는 2005년 "Content-based Music Audio Recommendation"을 소개하였다. 그는 음악에 사용된 악기의 정보와 음파에서 발생하는 리듬 및 화성을 통해 유사도 행렬을 구축하였다 [1]. G. Tzanetakis 는 음악에서 속성을 추출하는 방법에 대한 연구를 진행하였다 [2]. 그리고 장르를 자동적으로 검출해내는 실험을 통해 그가 제안한 방법의 우수성을 검증하였다. 따라서 본 논문은 G. Tzanetakis의 추출 방법을 이용한다. 또한 최근 B. Logan은 음악 내의 음파만을 이용하여 유사한 음악의 'song sets'으로 분류한 연구가 있다 [3]. 이는 본 논문의 연구와 매우 흡사하지만 그들의 방식에서는 MFCC (Mel Frequency Cepstral Coefficients) 방법을 이용하고 있다. 이는 13가지의 벡터값을 응용하는 것으로 본 논문에서 제안한 기법에 비해 많은 속성값을 사용한다. 하지만 음악 데이터는 매우 방대하며 급속하게 증가하고 있다. 그러므로 많은 속성을 고려하게 되면 시스템에 걸리는 부하가 커질 우려가 있다.

또 다른 방법은 협업 추천 방식이 있다. H. Chen은 그의 논문에서 이를 자세히 설명하고 있다 [4]. 그는 유사한 선호도를 가진 사용자들을 그룹화하고, 특정 사용자가 새로운 음악을 듣게 될 때 같은 그룹 내에 있는 사용자에게 음악을 추천하는 방식을 사용하고 있다. B. Yaprady는 인구 통계학적인 기법을 이용하여 협업 추천 방식을 구축하였다[5]. 이와 유사한 예로 국내에서 발표된 연구 중 상황 기반 추천 시스템이 있다 [6]. 사용자를 연령과 성별에 따라 그룹으로 묶는다. 그리고 기후와 온도 등의 외부적인 요인에 따라 그 날에 어울리는 음악을 추천하는 방식을 사용한다.

이와 같은 대부분의 연구는 사용자가 다른 성질의 여러 가지 음악을 좋아하거나, 변화하는 것에 대한 고려는 간과하고 있다. 본 논문은 이에 대해 중점을 두고 해결방법을 제안하고자 한다.

2.2 가변형 클러스터링 관련 연구

제안 시스템을 위한 가변형 K -means 방법과 관련된 대표 연구로는 리더 클러스터링과 IAFC 인공 신경망 알고리즘 등이 있다.

리더 클러스터링은 초기 클러스터의 수가 없이 데이터의 유사도를 기반으로 클러스터의 수를 결정해가는 대표적인 알고리즘이다 [7]. 리더 클러스터링 알고리즘은 데이터의 수나 클러스터의 수를 알지 못하는 경우에도 클러스터링 할 수 있다는 장점이 있는 반면 데이터의 순서에 따라 클러스터링의 결과가 크게 달라질 수 있다는 치명적인 단점이 있다. 한편 IAFC (Integrated Adaptive Fuzzy Clustering) 알고리즘은 고정된 클러스터로 인해 문제가 발생하는 기존의 인공 신경망 알고리즘을 보강하기 위해 적응형 퍼지 기술을 사용한 알고리즘이다 [8]. 이 방법은 클러스터의 수가 다를 경우 임계 파라미터 값을 조정하여 데이터의 클러스터링을 수행한다.

제안 시스템을 위한 가변형 K -means 방법이 리더 클러스터링이나 IAFC 알고리즘 혹은 기존의 유사 알고리즘과 다른 특징은 클러스터의 개수를 결정함에 있어서 클러스터의 직경을 제한하는 방법을 사용하고 있다는 것이다. 직경을 제한하는 것 외에는 기존의 K -means 방법과 동일하기 때문에 K -means 방법의 장점을 모두 수용하여 사용할 수

있다는 장점이 있다. 본 논문에서는 가변형 K -means 알고리즘을 제안하며 이를 통한 음악 추천 시스템을 구성한다.

3. 제안 시스템

본 절에서는 음악 추천을 위한 제안 시스템에 관한 설명을 기술한다. 제안 시스템의 전체 과정은 시간 가중치를 통한 사용자의 선호도 변화 분석 단계, 음파 분석 기법 단계, 가변형 K -means를 이용한 사용자 분석 단계, 가변형 선호하는 군집 분석 단계, 가변형 선호하는 음악 발매 시기 집 단계, 그리고 음악 추천 리스트 작성 단계의 여섯 단계로 구성된다.

3.1 시간 가중치를 통한 사용자의 선호도 변화 분석

사용자의 선호도는 시간이 흐름에 따라 변화한다. 예전에는 조용한 음악을 선호하였으나, 근래에는 경쾌한 음악을 선호하게 된 사용자가 있다고 가정하자. 이와 같은 경우 예전에 선호하였던 음악에 대한 가중치를 낮춰줄 필요가 있다. 이를 분석하기 위해서 음악을 선택할 때마다 각각에 연번을 저장한다. 처음 선택한 음악은 1로 정하고 이후 선택할 때 마다 이를 1씩 증가시켜 나간다. 또한 시간에 따라 감소하는 비율인 δ 를 정의한다. 그리고 정의된 두 가지 속성을 이용하여 각 음악에 대한 중요도, 즉 시간 가중치 값을 나타낼 수 있다. 그러므로 어떠한 후보 음악 m 이 존재할 때 $Time_{weight}$ 는 다음과 같은 수식으로 표현할 수 있다.

$$Time_{weight} = \delta^{(N-n-1)} \quad (\text{where } 0 < \delta < 1) \quad (1)$$

식 (1)에서 δ 는 시간에 따른 감소하는 비율을 나타낸다. 이 때 δ 는 반드시 0보다 크고 1보다 작은 수로 택한다. 그리고 N 은 사용자가 선택한 음악의 수를 의미하고, n 은 음악 m 의 연번을 뜻하며 이것은 사용자가 음악을 선택했던 순서를 나타낸다. 예를 들어 음악 m_1, m_2, m_3 를 순서대로 선택했을 경우 가장 최근에 선택한 m_3 의 $Time_{weight}$ 는 δ^0 가 되고 m_2 는 δ^1 , m_1 은 δ^2 가 된다. 또한 이와 같은 설계 하에서는 곡을 선정 시, 한 곡을 여러 번 선택할 경우 기본적으로 이를 반영하여 재설정되는 것을 알 수 있다.

3.2 음파 분석 기법

음악이란 음파로 이루어져 있다. 음파의 특징 종류로는 음률의 높이 (pitch), 소리의 세고 여림 (loudness), 음의 길이 (duration), 음질 (timbre)등이 있다. 상기와 같은 많은 속성들이 있지만 본 논문에서는 STFT (Shortest Time Fourier Transform) 기법을 통해 얻을 수 있는 ZCR (Zero Crossing Rate), Spectral roll-off, Spectral Flux를 이용한다. 이들은 음성 구간 추출이나 특정 구간 내에 음악을 검색하는데 사용되었고 우수한 성능을 보였다 [4][7]. 이 속성들은 수치적 데이터로 표현되므로 좌표값 형식으로 나타낼 수 있고, 이는 3차원 공간에 하나의 점으로 사상된다.

ZCR (Zero Crossing Rate): ZCR은 주어진 구간 내에 음성 신호가 기준선인 0을 통과하는 횟수를 측정하는 것이다. 즉, 이산 신호에서 연속 샘플링 값이 서로 다른 부호일 때 발생하는데, 이는 음성의 분할, 분석, 인식에 매우 유용하게 쓰인다. 음성의 신호의 크기를 x 라 하고 샘플 n 에 대한 t 차 ZCR Z_t 는 다음과 같이 정의된다 [4].

$$Z_t = \sum_{n=1}^N \frac{|sign(x[n]) - sign(x[n-1])|}{2} \quad (2)$$

Spectral Rolloff: Spectral roll-off는 음성 구간과 무음 구간 사이를 구분하는 특징으로써 centroid와 함께 스펙트럼 형태의 또 다른 측정 방법이다. roll-off의 정의는 크기 (magnitude) 분포의 85%가 집중해 있는 주파수 M_t 이하를 말한다. 즉, 신호의 에너지 중 낮은 신호에 얼마나 많이 집중 되어 있는가를 보여준다 [4].

$$\sum_{n=1}^{R_t} M_t[n] = 0.85 \times \sum_{n=1}^N M_t[n] \quad (3)$$

Spectral Flux: Spectral Flux는 스펙트럼의 변화율을 측정하는 방법으로써 연속된 스펙트럼의 분포의 정규화 된 크기들의 차를 제공한 것을 의미한다. Flux는 음악과 음성을 구분 짓는데 적합하다 [4].

$$F_t = \sum_{n=1}^N (N_t[n] - N_{t-1}[n])^2 \quad (4)$$

여기서 $N_t[n]$, $N_{t-1}[n]$ 은 각각 현재 프레임 t 와 이전의 프레임 $t-1$ 에서 Fourier transform의 정규화 된 크기를 의미한다. Spectral Flux는 음색을 판단하는데 중요한 지표가 된다. 본 논문에서는 이상의 음파 분석 기법인 식 (2)에서 식 (4)를 음악 파일 전체에 대하여 적용하여 사용한다.

3.3 가변형 K -means 기법을 이용한 사용자 선호도 분석

사용자의 음악 리스트는 사용자가 음악을 선택할 때 이를 저장하게 된다. 따라서 사용자의 리스트는 선호도를 가시화할 수 있는 자료라고 볼 수 있다. 그러므로 사용자의 리스트를 분석한다면 사용자의 취향을 알아낼 수 있다. 사용자의 리스트를 통해서 선호도를 분석하는 방법으로 평균을 내는 방법이 있다. 하지만 이것은 좋은 지표가 될 수 없다. 만약 사용자가 전혀 다른 두 가지 장르의 음악을 선호한다고 가정하자. 그렇다면 이는 적절한 추천이 불가능하다. 예를 들어 어떤 사용자가 클래식과 락 장르의 음악을 선호한다면, 평균값이 나타내는 좌표 주변의 음악들은 클래식뿐만 아니라 락 또한 아닐 것이다. 근래에 많은 음악 추천에 관련한 연구가 있었다. 하지만, 대부분 여러 가지 종류가 아닌 한 가지 종류만을 선호한다고 가정하고 있다. 그러므로 평균 연산이라는 간단한 방법을 통해 사용자의 선호도를 나타낼 수 있었다. 본 논문은 사용자들이 다른 장르의 음악을 선호할 수 있다고 가정한다. 이를 위해 본 논문에서는 군집화 기법을 응용한다. 사용자의 리스트를 좌표축에 사상하여 생성되는 군집의 중심점을 사용자의 선호도라고 판단한다. 만약 어떤 사용자가 두 가지 장르의 음악을 선호할 경우 두 개의 군집이 생성될 확률이 높아진다. K -means 알고리즘은 군집을 형성하고 분석하는 비교 학습으로써 간단하지만 매우 효율적인 기법이다. 하지만 K -means 알고리즘은 군집의 개수뿐하여 K 의 값을 입력 받아야 한다는 문제점을 내포하고 있다. 하지만 사용자에 따라 생성되는 군집의 수는 모두 다르며, 이를 예측하는 방법은 쉽지 않다. 따라서 동적으로 군집의 수를 조절할 수 있는 알고리즘이 필요하다. 그리고 또 다른 문제점을 가지고 있다. 특정 군집의 크기가 커질 때 발생하는 것으로 그림 1과 같은 두 개의 군집이 있다고 가정하자. 두 군집의 중심점은 사용자의 선호도

를 나타나게 된다. 따라서 중심점과 가까운 음악들을 추천하게 된다.




그림 1. 군집화 예제: 사용자의 선호도를 부적합하게 나타낸 예제

Fig. 1. Example of a large cluster: improper to represent a user's preference

위와 같은 경우 P_1 와 P_2 는 추천되지만 P_3 는 추천되지 않을 수 있다. P_3 는 사용자가 선택한 음악들과 유사함에도 불구하고, 이는 중심점으로부터 멀어지게 되어 결과적으로 추천되지 않게 된다. 따라서 본 논문은 군집의 직경을 제한하는 방법을 제시한다. R_{max} 는 군집의 최대직경을 나타내며, 이를 통해 유동적으로 군집의 수를 조절할 수 있다. 특정 군집의 직경이 R_{max} 보다 커질 경우, 군집의 수인 K 를 증가시킨다. 모든 군집의 직경이 R_{max} 보다 작아질 때까지 이를 지속적으로 반복한다.

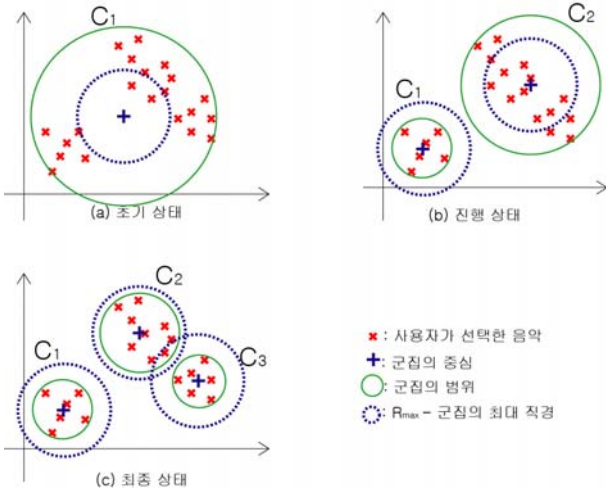


그림 2. 가변형 K-means Clustering의 실행 과정
Fig. 2. Clustering steps

그림 2는 군집화 과정을 나타낸다. 초기 상태의 경우 군집의 수는 1로 시작한다. 따라서 2-(a)와 같이 하나의 군집으로 나타나게 된다. 하지만 초기 상태의 군집의 직경은 R_{max} 보다 크다. 따라서 군집의 수를 2로 증가시키게 되며 이는 그림 2-(b)처럼 나타나게 된다. 하지만 C_2 의 군집의 직경이 여전히 R_{max} 보다 큰 상태이다. 그러므로 군집의 수를 다시 증가시키며 그림 2-(c)의 상태가 된다. 그림 2-(c)일 때 모든 군집들은 R_{max} 보다 작아지게 되며 이는 최종적인 결과값이 된다.

R_{max} 는 시스템 관리자에 의하여 정해지는 수치이며, 수

치가 작아질수록 군집의 수가 증가하는 경향을 보인다. 이 방법을 적용하기 위해서는 좌표축에 나타나는 각각의 속성값의 범위를 알고 있어야 한다. 본 논문은 각각의 속성을 평균값에 의해 나뉘지게 되므로 범위를 예측할 수 있었다. 이처럼 데이터의 범위를 알고 있다면, 가변형 K-means 기법은 효율적인 방법이 된다.

일반적인 K-means 알고리즘 기법의 경우 해당 군집에 속하는 좌표들의 평균값을 통해 중심값을 찾게 된다. 하지만 이 방법은 모든 좌표들이 같은 중요도를 가질 때 적용된다. 하지만 본 논문에서 사용하고 있는 속성들은 3.1절에서 제시한 바와 같이 시간 순서에 따라 가중치가 변하게 된다. 따라서 특정 클러스터 k 의 중심 값(v_c)은 식 (5)를 통해 구할 수 있다.

$$v_c = \frac{\sum_{Cluster_k} Music_{property} \times Time_{weight}}{\sum_{Cluster_k} Time_{weight}} \quad (5)$$

식 (5)에서 사용된 $Music_{property}$ 은 3.2장에서 제안한 음과 분석에 의해 추출된 속성값으로 음악 m 의 (ZCR, Rolloff, Flux)을 나타내며, $Time_{weight}$ 는 3.1장에서 의해 구해진 음악 m 에 대한 시간 가중치 값이다. 식 (5)의 우변의 분모는 군집에 소속된 시간 가중치의 합을 나타낸다. 그리고 분자는 시간 가중치와 속성값을 곱해준 합을 나타내며 결과적으로 시간 가중치의 중요도를 고려한 중심점을 찾게 된다.

3.4 사용자가 선호하는 군집 분석

3.3절의 기법을 응용하여 사용자가 선호하는 음악을 군집화 할 수 있었다. 대부분의 경우 최대 직경 R_{max} 의 제한을 받아 군집의 크기가 비슷한 경우가 많다. 하지만 군집을 형성하는 사용자의 리스트의 수는 모두 다르다.




그림 3. 군집을 이루는 사용자 리스트의 수 비교
Fig. 3. Comparison of dense cluster and sparse cluster

예를 들어 그림 3을 봤을 때 C_1 을 구성하고 있는 사용자의 리스트가 C_2 에 비해 월등히 많다. 이 때 추천하고자 하는 후보 음악의 위치가 군집의 중심과 떨어진 거리가 같다고 가정하면, C_1 에 속해 있는 후보 음악이 C_2 에 속해 있는 후보 음악 보다 더 높은 가치를 가질 것이다. 따라서 보다 높은 중요도를 가지는 군집을 분석하고 이를 반영할 필요가 있다. 이를 ‘군집 가중치’라고 하며, 어떠한 군집 k 가 존재할 때 해당 군집의 가중치 $kCluster_{weight}$ 는 다음 식을 통해 구할 수 있다.

$$kCluster_{weight} = \frac{\sum_{Cluster_c} Time_{weight}}{\sum_{All} Time_{weight}} \quad (6)$$

식 (6)에서 표현된 분모에 대한 식은 사용자가 선택한 모

든 음악의 시간 가중치 합을 의미한다. 그리고 분자의 식은 특정 군집 k 에 포함되어 있는 모든 음악의 시간 가중치 합을 의미한다. 결과적으로 이것은 특정 군집 k 의 비율을 나타낼 수 있으며 중요도로 활용될 수 있다.

3.5 사용자가 선호하는 음악 발매 시기 분석

대부분의 음악 포털 사이트들은 음악 순위를 제공하고 있다. 하지만 대부분의 경우 근래에 발매된 음악 위주로 구성되어 있다. 이는 젊은 층에게 좋은 반응을 얻을 수 있을 것이다. 하지만 중장년층의 경우 오래 전에 발매된 음악을 선호하는 경우가 많다. 따라서 음반의 발매 시기는 사용자의 선호도 분석에 있어 중요한 평가 기준이 된다. 본 논문은 음악의 발매시기를 다음과 같은 시기로 분석한다. 70년대 이전, 70년대, 80년대, 90년대, 2000년대, 금년. 단 클래식 음악의 경우 모두 70년대 이전의 음악이라고 선언하고 실험을 진행하였다. 이 절에서 또한 사용자가 음악을 들었던 시기가 중요한 고려대상이 된다. 따라서 3.1절에서 적용하였던 방법을 여기에서도 적용하게 된다. 이 방법을 통해 사용자의 리스트에 소속된 음악이 사용자의 선호도에 미치는 중요도를 판단하는 요소를 추출한다. 그리고 이를 기간 가중치라고 정의한다. 특정 기간 p 에 대하여 기간 가중치는 P_m 으로 표현하며 이는 다음 식을 통해 구한다.

$$P_m = \frac{\sum_{Year} Time_{weight}}{\sum_{All} Time_{weight}} \quad (7)$$

식 (7)에서 우변의 분모는 사용자가 선택한 모든 음악의 시간 가중치 합을 나타낸다. 그리고 분자는 사용자가 선택한 음악 중 p 기간에 소속된 음악을 뜻한다. 이는 3.4절의 군집 가중치와 비슷한 연산 방식을 취하며 어떠한 시기를 사용자가 선호하는 지를 나타내는 지표가 된다.

3.6 음악 추천 리스트

사용자에게 음악을 추천하기 위해 DB에 저장된 후보 음악에 점수를 부여한다. 어떠한 후보 음악 m 이 k 군집에 존재하고 발매된 시기가 p 구간일 때의 점수는 다음과 같이 정의한다.

$$Score_m = \frac{1}{(v_c, Music_{property})} \times \frac{\sum_{Cluster_c} Time_{weight}}{\sum_{All} Time_{weight}} \times P_m \quad (8)$$

위 식에서 분모의 연산은 유클리디안 거리 연산을 이용하여 군집의 중심으로부터 음악 m 의 거리를 계산한다. 군집의 중심에 가까울수록 큰 점수를 도출하기 위해 역수를 취한다. 그리고 앞장에서 설명된 군집 가중치 및 기간 가중치를 이용하여 후보 음악 m 에 대한 중요도를 평가한다. 결과적으로 높은 점수를 얻게 되면 사용자가 보다 선호하는 음악이라고 볼 수 있으며, 추천 결과물은 내림차순으로 정렬되어 나타내게 된다.

4. 실험 결과

제안한 방법의 유용성을 보이기 위하여 실험을 진행하였다. 실험 진행에 앞서 발라드, 락, 재즈, 클래식 장르의 음악

을 각각 25곡씩 추출하여 100곡의 음악 데이터베이스를 구축하였다. 각각의 음악파일은 32bit 2채널 44100Hz 형식으로 구성되었다. 각각의 속성은 음악의 길이에 의해 1차적으로 나누어진다. 이 과정을 통해 음악의 길이에 무관하게 적용이 가능하다. 각각의 속성들은 해당 속성의 평균값에 의해 나누어진다. 예를 들어 ZCR의 경우 ZCR의 평균값에 의해 나뉜다. 상기 두 가지 방법을 거치면 각각의 값들은 정규화 된 분포를 가지게 된다. 또한 그 분포는 대부분 0에서 2사이의 값을 가지게 되었다. 본 논문에서 제시하였던 방법인 가변형 K -means에 사용되는 최대 직경, 즉 R_{max} 는 0.5로 가정하였다. 그리고 시간 가중치를 적용하기 위한 시간 감소율은 0.9로 적용하였다. 사용자가 다음과 같은 클래식 장르의 세 가지 음악을 들었다고 가정했을 때, 음악이 추천 되는 과정을 단계별로 나타내면 다음과 같다.

- Mozart - Piano sonata no. 21, 발매 시기 = 70년대 이전
- Bizet - Carmen suite no. 2, 발매 시기 = 70년대 이전
- Vivaldi - Four season: autumn the 1st movement, 발매 시기 = 70년대 이전

(ZCR, Roll-off, Flux)의 구해진 속성값 / 음악의 길이(초), 시간 감소율: 0.9

- (179895, 6997, 115) / 101, 시간 감소율 = 1
- (216980, 4593, 321) / 100, 시간 감소율 = 0.9
- (474532, 24881, 1306) / 197, 시간 감소율 = 0.81

정규화 된 속성값:

- (0.681803, 0.239239, 0.017864)
- (0.670454, 0.173551, 0.020516)
- (0.922062, 0.436176, 0.103693)

이를 본 논문에서 제안한 군집화 알고리즘에 적용하면, 하나의 군집이 형성되고 중심값은 다음과 같다.

- (0.677361, 0.249579, 0.040107)

구해진 중심값을 기준으로 가장 높은 점수를 받은 음악을 추천하게 된다. 추천된 결과값은 표 1이 보이는 바와 같다. 본 논문이 제안하는 음악 추천 시스템은 대체적으로 클래식 음악을 추천해주는 것을 볼 수 있다. 재즈 음악은 가수가 없는 경우가 있고 전반적으로 클래식과 유사한 점이 많다. 따라서 5번째에 추천된 음악에는 재즈가 나타나고 있다.

두 번째 실험은 사용자가 어떠한 하나의 장르의 음악만 선호하는 경우에 대한 실험을 진행하였다. 하나의 장르에서 5개의 음악을 무작위로 선택하게 하고, 위 실험을 10회 반복하였다. 그리고 각 장르별로 그 결과값을 살펴보았다. 표 2는 추천된 음악 중 상위 5개에 대한 장르별 비율을 나타낸 것이다. 사용자가 발라드 음악만을 선택했을 경우 62%의 발라드 음악이 선택되었고 16%의 락 음악, 22%의 재즈 음악과 0%의 클래식 음악이 추천되었다. 락 음악만을 선택한 경우 발라드 22%, 락 72%, 재즈 6%, 클래식 0%로 나타났다. 표 2가 보이는 바와 같이 제안 방법을 사용하였을 때, 사용자가 선호하는 장르의 음악을 가장 많이 추천되어짐을 알 수 있었고 이는 음악 추천 시스템이 사용자의 선호도를 반영하여 추천하는 것을 말해준다.

표 1. 클래식 음악에 따른 추천 결과

Table 1. Music recommendation in classical

순위	제목	속성	장르	기간
1	Bizet - Minuet	(0.671, 0.174, 0.020)	클래식	70년대 이전
2	Guno - Ave maria	(0.733, 0.382, 0.065)	클래식	70년대 이전
3	Saint saens - The swan	(0.564, 0.153, 0.010)	클래식	70년대 이전
4	Kreisler - Leibesleid	(0.788, 0.447, 0.139)	클래식	70년대 이전
5	Billie holiday - Georgia on my mind	(0.426, 0.447, 0.139)	재즈	70년대 이전

표 2. 단일 장르 추천 결과

Table 2. A user listens to music of a single genre

사용자 리스트 / 추천 결과	발라드	락	재즈	클래식
발라드	62%	22%	24%	0%
락	16%	72%	8%	0%
재즈	22%	6%	64%	12%
클래식	0%	0%	14%	88%

다음은 사용자의 선호도가 변하는 경우에 대한 실험을 하였다. 1990년대의 락 음악을 좋아하였으나 근래에 들어서 2000년도의 발라드 음악을 좋아한다고 가정하였다. 하지만 락 음악과 발라드 음악을 들었던 횟수는 3회로 동일하게 진행하였다. 또한 이것은 앞에서 제시한 단일 장르 테스트와 동일하게 10회에 걸쳐서 진행하였다. 결과적으로 2000년도의 발라드 음악이 48%로 가장 많이 추천되었고 2000년대의 락 음악이 20%로 그 뒤를 이었다. 그리고 1990년대의 락 음악이 14%로 나타났다. 결과를 통해 근래에 들었던 음악을 더 중요한 요소로 작용하고 있음을 알 수 있다. 표 3은 1990년대 락 음악에서 2000년대 발라드 음악을 선호하게 된 사용자의 추천 결과를 보인다.

표 3. 1990년대 락 음악에서 2000년대 발라드 음악을 선호하게 된 사용자의 추천 결과

Tabel 3. A user listens to music ballad music in 2000s and rock music in 1990s

추천 결과 / 발매 시기	2000년대	1990년대
발라드	48%	12%
락	20%	14%
재즈	4%	2%
클래식	0%	0%

최종적으로 사용자가 락과 클래식 음악을 좋아한다고 가정하였다. 두 가지 장르의 음악을 동등한 비율로 적용하기 위해 이 실험에서는 시간에 따른 가중치를 적용하지 않았다. 사용자는 각 장르에서 5개의 음악을 들었고 이 실험을 10회 반복하였다. 본 논문은 이 실험을 통해 기존의 K-means 기법과 가변형 K-means 기법을 비교하였고 표 4가 보이는 바와 같다. K-means 기법의 경우 군집의 수를 1에서 4까지 직접 입력하여 진행하였다. K가 1일 경우 군집의 수는 하나가 되며, 이는 다른 논문이 적용하고 있는 단순한 평균값 연산과 동일한 기법이 되었다. 이 경우 락이나 클래식 음악이 아닌 발라드 음악이 60%로 가장 많이 추천되고 있음을 알 수 있다. 락 25%, 재즈 16%, 클래식 4%가 추천되었으며 사용자의 선호도와 부합되는 것은 락과 클래식의 비율을 합친 29%에 불과했다. K가 증가할수록 사용자의 선호도에 맞게 변하는 것을 볼 수 있다. 일반적으로 K가 증가될수록 정밀한 분석이 가능하게 된다. 하지만 K가 증가할수록 군집이 커지며, 이로 인해 연산을 위해 걸리는 시간이 길어지게 된다. 따라서 K의 수는 매우 신중하게 고려되어야 한다. 하지만 상황에 따라 K는 매번 변하게 되므로 이를 정하는 것은 쉽지 않다. 기존의 K-means의 경우 K의 값이 3에서 4가 될 경우 좋은 추천 결과를 보이게 된다. K가 4일 경우 락 음악이 36%이고 클래식 음악이 44%이다. 그러므로 80%의 음악이 사용자의 선호도에 부합되었다고 볼 수 있다. 본 논문이 제시한 가변형 K-means를 이용한 경우 74%(락 34% + 클래식 40%)가 사용자의 선호도에 부합되었다. 따라서 본 논문에서 제시한 방법이 사용자의 선호도를 올바르게 반영할 뿐만 아니라 사용자의 개입 없이 군집의 수를 조절하고 그 결과값을 도출하고 있음을 알 수 있었다. 3.4절에서 언급한 바와 같이 R_{max} 의 값이 클수록 K값은 커질 수 있다. 실험에 따라 변동이 있지만 R_{max} 값이 0.5일 때, 제안 알고리즘이 가장 정확한 추천의 결과를 보임을 확인하였다. 이때 가변형 K-means 방법을 통해 형성된 K값은 실험에 따라 5~8의 값을 보였다. 표 4는 락 음악과 클래식 음악을 선호하는 사용자의 추천 결과를 보인다.

표 4. 락 음악과 클래식 음악을 선호하는 사용자의 추천 결과 (시간 순서를 고려하지 않음)

Table 4. A user listens to music of two genre of music: rock and classical

사용자 리스트 / 추천결과	일반 K-means				가변형 K-means K(5~8)
	K=1	K=2	K=3	K=4	
발라드	60%	32%	16%	8%	10%
락	20%	16%	40%	36%	34%
재즈	16%	4%	8%	4%	6%
클래식	4%	48%	36%	44%	40%

5. 결론

본 논문은 개인화된 음악 추천 시스템을 제시하고 있다. 그리고 사용자가 어떤 음악을 선택하고 있는지에 대한 시간

적인 순서를 고려하고 있다. 최근에 얻게 된 데이터는 과거에 비해 보다 높은 가치를 가진다. 따라서 과거의 데이터의 중요도를 감소시켜야 한다. 또한 음악을 추천하기 위해서는 분석을 하여야 한다. 이를 위해 음악을 구성하고 있는 음파에서 여러 가지 속성을 추출해 낸다. 그리고 사용자가 음악을 선택하게 될 때 이를 리스트에 저장하고, 리스트를 분석하여 사용자의 선호도를 예측한다. 대부분의 연구는 사용자가 선호하는 음악을 하나의 장르로 국한시키는 경우가 많다. 본 논문은 여러 가지 장르의 음악을 선호할 경우를 대비하여 K -means 기법을 적용한다. 기존의 K -means의 기법은 반드시 군집의 수를 정해줘야 한다는 단점이 있다. 하지만 군집의 수는 모든 상황에 따라 달라진다. 따라서 군집의 수를 유동적으로 조절할 수 있는 알고리즘이 필요하며 본 논문은 가변형 K -means 기법을 제시한다. 이 기법들을 응용하여 단일 장르 테스트, 시간을 고려한 두 가지 장르 테스트 및 동등한 조건의 두 가지 장르 테스트를 진행하였고, 각각의 실험은 사용자가 선호하였던 장르에 맞게 추천 되어짐을 확인할 수 있었다.

참 고 문 헌

- [1] P. Cano, M. Koppenberger, N. Wack, "Content-based Music Audio Recommendation," *Proc. of ACM International Conference on Multimedia*, pp. 211-212, 2005.
- [2] G. Tzanetakis, P. Cook, "Musical genre classification of audio signals," *IEEE Trans. Speech and Audio Processing*, pp. 293-302, 2002.
- [3] B. Logan. "Music Recommendation from Song Sets," *Proc. of ISMIR*, pp. 425-428, 2004.
- [4] H.C. Chen, A.L.P. Chen. "A Music Recommendation System based on Music Data Grouping and User Interests," *Proc. of CIKM*, pp. 231-238, 2001.
- [5] B. Yaprıady, A.L. Uitdenbogerd, "Combining demographic data with collaborative filtering for automatic music recommendation," *Lecture notes in computer science*, Springer, pp. 201-207, 2005.
- [6] 유지오, "퍼지 베이지안 네트워크와 효용성 이론을 사용한 상황 기반 음악 추천," 연세대학교, *PhD thesis*, Feb, 2006.
- [7] R.O. Duda, P.E. Hart, D.G. Stork, "Pattern classification 2nd," *Wileyinterscience*, 2001.
- [8] Y.S. Kim, S. Mitra, "Integrated Adaptive Fuzzy clustering (IAFC) Algorithm," *Proc. of the Second IEEE International Conference on Fuzzy Systems*, Vol. 2, pp. 1264-1268, San Francisco, 1993.

저 자 소 개



김재광(Jaekwang Kim)

2004년 : 성균관대 정보통신공학부 학사
 2006년 : 성균관대 컴퓨터공학과 석사
 2007년 : 성균관대 정보통신기술연구소 연구원
 2008년~현재 : 성균관대 전자전기컴퓨터 공학과 박사과정

관심분야 : 네트워크 보안, 기계학습, 지능시스템
 Phone : +81-31-290-7987
 Fax : +81-31-299-4637
 E-mail : linux@ece.skku.ac.kr



윤태복(TaeBok Yoon)

2001년 : 공주대학교 전자계산학과 학사
 2003년 : (주)디지털솔루션
 2005년 : 성균관대학교 컴퓨터공학 석사
 2005년~현재 : 성균관대학교 컴퓨터공학 박사과정

관심분야 : 게임 A.I., User Modeling
 Phone : +81-31-290-7987
 Fax : +81-31-299-4637
 E-mail : tbyoon@skku.edu



김동문(Dongmoon Kim)

2006년 : 동국대학교 컴퓨터공학과 학사
 2008년 : 성균관대학교 전기전자컴퓨터 공학과 석사
 2008년~현재 : Tmax soft.

관심분야 : CRM, 데이터 마이닝, Personalized System
 Phone : +81-31-290-7154
 Fax : +81-31-299-4637
 E-mail : sky_scrape@skku.ac.kr



이지형(Jee-Hyoung Lee)

1993년 : 한국과학기술원 전산학과 학사
 1995년 : 한국과학기술원 전산학과 석사
 1999년 : 한국과학기술원 전산학과 박사
 2002년~현재 : 성균관대 정보통신공학부 부교수

관심분야 : 지능시스템, 기계학습, 지능형 웹
 Phone : +81-31-290-7154
 Fax : +81-31-299-4637
 E-mail : jhlee@ece.skku.ac.kr