

3G-6

ユーザ嗜好に基づく音楽情報検索システムのための学習データ抽出手法

石先広海† 帆足啓一郎‡ 松本一則‡ 甲藤二郎†
 早稲田大学理工学研究科† KDDI 研究所‡

1 はじめに

ユーザ嗜好に基づいた音楽情報検索システムでは、予め用意していたジャンル情報を基に特徴空間を構築している。しかし、学習用の音楽データと検索対象となる音楽データの特徴が大きく異なっていると、特徴空間内の検索対象データの分布が偏ってしまい、ユーザの嗜好が検索結果に反映されないことがある。そこで本稿では検索対象楽曲のクラスタリングを行い、各クラスタから学習データの抽出を行なうことで、特徴空間を再構築させ検索精度の向上を図る。

2 ツリーベクトル量子化手法

参考文献[1]で提案されている音楽情報検索システムでは Foote が提案したツリーベクトル量子化手法(TreeQ)[2]を基に音楽情報のベクトル化を行っている。TreeQ ではツリー作成の際、正解カテゴリが付与されている学習データ(音楽データ)に基づいて、学習データが分類されるように最適化されたツリーを生成する。次に生成されたツリーに個々の音楽データ、あるいはカテゴリに属する全音楽データの MFCC のフレームを入力し、そのフレームが到達する葉(leaf)を求める。そして、各 leaf に到達したフレーム数を算出して得られるヒストグラムを各音楽データまたはカテゴリをあらわすベクトルとしている。図1にその概要を示す。

3 ユーザ嗜好に基づく音楽情報検索システム概要

本システムでは、まず事前準備として TreeQ に基づき全検索対象データのベクトル量子化を行なう。システム利用時では、ユーザに好みのジャンル、または楽曲を選んでもらい、その情報に基づいて、ユーザ嗜好ベクトル(ユーザプロフィール)の作成を行なう。このユーザ嗜好ベクトルと各検索対象データの特徴ベクトルのベクトル類似度を計算し、類似度の高いものからユーザに検索結果として提示する。またユーザは、提示された楽曲に対しての評価を行い、その評価結果から適合フィードバックを用いて、ユーザプロフィールを更新していく。

4 問題点

既存のシステムでは、カテゴリ情報が付与された学習データを用いて検索対象データのベクトル化を行っている。カテゴリ情報の例としては、アーティスト、ジャンル情報などが挙げら

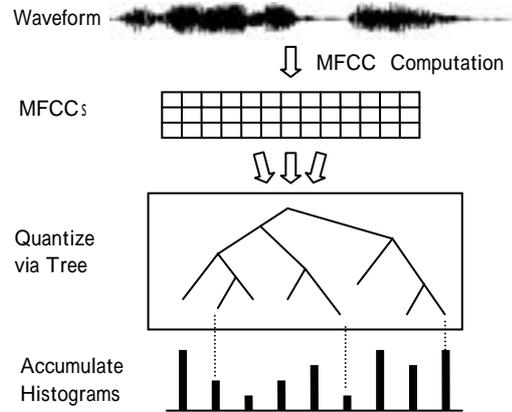


図1 ツリーベクトル量子化手法概要

れる。TreeQ では音響的特徴に基づいて検索対象データを分類させているため、アーティスト情報を用いた場合、データとして適さない可能性がある。一方、ジャンル情報では、各ジャンルによって音響的特徴が似通ったものであると予想されるため、学習データとして適していると考えられる。しかし、この学習データと検索対象データの特徴があまりにも違っている場合、検索対象データの特徴空間を構築する際に偏りが生じてしまう可能性がある。この偏りにより、音楽情報検索の精度が劣化すると予想される。

5 提案手法

上記した問題点を改善するために学習データを検索対象データの中から抽出する手法を提案する。以下に簡単な流れを表記する。

1. ジャンル情報の付与された音楽データを学習データとして、ベクトル量子化ツリーを生成する。
2. 生成されたツリーを基に全検索対象データのベクトル量子化を行なう。
3. 全検索対象データの特徴ベクトルを k-means 法によってクラスタリングを行なう。
4. クラスタ分類された各クラスタからそれぞれ n 個の学習データを抽出する。
5. 抽出された学習データより、再びベクトル量子化ツリーを生成し、そのツリーを基に検索対象データのベクトル量子化を行なう。

本提案では、検索対象データに対してクラスタリングを行ない、その結果より抽出された学習データによってベクトル量子化ツリーを再形成することで、検索対象データの特徴空間の分布の偏りを改善させる。つまり、クラスタリン

Training data extraction method for user-preference based music information retrieval system

†Graduate school of Science & Engineering, Waseda University

‡KDDI R&D Laboratories Inc.

グ結果に基づいた検索対象データから学習データを抽出することで、検索対象データのベクトル量子化を行なうために最適なツリーを形成することができると考えられる。

5 実験データ

以下の実験に用いたデータは、学習データとして RWC 研究用音楽データベースのジャンル情報[3]の中分類, 100 曲を用いた。検索対象データとして、HMV japan の Web ページ[4]に掲載されている週間売り上げランキングデータより、2001 年 1 月～12 月のトップ 10 にランクされたアルバム 120 枚中の楽曲データ及び、コロムビア大学より提供されている us pop data set [5]を基に収集した合計 6863 曲のデータを使用した。

また、ユーザの音楽的嗜好のデータを収集するため、被験者 28 名に従来システムを利用してもらい、それぞれが試聴した曲に対して 5 段階の主観評価(好き: 5～嫌い: 1)を行なってもらい、その評価に基づき、各々が試聴したデータを 2 つのカテゴリ(C_g , C_b)に分類する。 C_g , C_b はそれぞれ、評価値 4 以上, 2 以下の音楽データをそれぞれ分類する。

6 構築された特徴空間の比較

まず、特徴空間における分布の偏りを比較するために学習データからツリーを生成し、RWC 研究用音楽 DB のジャンル情報に基づき各ジャンルの特徴ベクトルを作成する。そのベクトルと全検索対象ベクトルとの類似度を計算する。各楽曲は最も類似度の高かったジャンルに属するものとする。以上の方法で各検索対象データがどのジャンルに分類されるか調査を行った。また提案手法についても同様の調査を行った。

その結果、従来手法では pops に属するものが 5851 曲(全体の 85%)であり、従来手法による特徴空間の構築に偏りが発生する事がわかった。

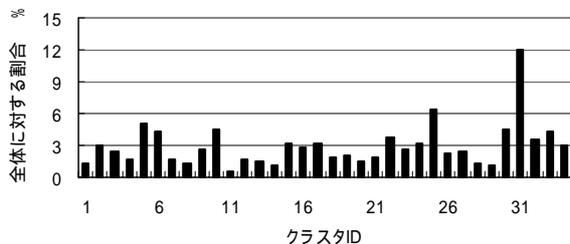


図 2 提案手法における全曲のクラスタ分布

一方、提案手法では図 2 に示された各クラスタに分類された楽曲の割合から明らかのように、一様なクラスタ分布を形成することができている。

クラスタに属している楽曲数は最大でも 819 曲(全体の約 12%)で、クラスタリングを行うことで特徴空間の偏りが改善されることがわかった。

7 検索精度比較実験・結果

次に、特徴空間再形成による検索結果への影響を調べるために、検索精度の比較実験を行なった。

まず、カテゴリ C_g , C_b からそれぞれランダムに 5 曲ずつ抽出し、ユーザプロフィールを作成する。ユーザプロフィールと全曲の類似度を計算させ、従来手法と提案手法それぞれ類似度上位 50 曲を出力させる。その上位 50 曲の中に、カテゴリ C_g , C_b に属する楽曲の出現率の比較を行なった。なお、ここでは学習データ数を 3、総クラスタ数を 34 としている。

検索精度の比較実験の結果を表 1 に示す。表 1 は検索結果上位 50 曲に、ユーザが未試聴の楽曲やユーザ評価が 3 である楽曲も含まれている状態で求められた検索精度である。提案手法においては、従来手法の倍以上の楽曲が上位 50 曲に検索された。このことから、提案手法の有効性が示されていると考えられる。

表 1. 評価結果

カテゴリ	従来手法	提案手法
C_g	11.6%	26.4%
C_b	8.0%	7.4%

8 まとめ

本研究では、ユーザの音楽的嗜好に基づく音楽情報検索システムの精度向上のために、検索対象データの特徴ベクトルに対してクラスタリングを行なうことで、新たな学習データの抽出を行い、特徴空間の再構築を行なった。また評価実験を行い、評価実験の結果、検索精度の向上が見られ、提案手法の有効性が確認された。

参考文献

- [1] K. Hoashi, K. Matsumoto, N. Inoue: Personalization of User Profiles for Content-based Music Retrieval Based on Relevance Feedback, Proceedings of ACM Multimedia 2003, pp 110-119, November 2003.
- [2] J.T. Foote: "Content-based retrieval of music and audio", Proceedings of SPIE, Vol 3229, pp138-147, 1997.
- [3] 後藤 真孝, 橋口 博樹, 西村 拓一, 岡 隆一: "RWC 研究用音楽データベース: 音楽ジャンルデータベースと楽器音データベース", IPSJ SIG Notes, 2002-MUS-45, pp19-26, 2002.
- [4] HMV japan: <http://www.hmv.co.jp>
- [5] USpop Data Set: <http://www.ee.columbia.edu/~dpwe/research/musicsim/uspops2002.html>