

より良い音楽推薦システムへ向けた試み

The trial for a better music recommendation system

西尾毅士*1
Takashi Nishio

田村哲嗣*2
Satoshi Tamura

速水悟*2
Satoru Hayamizu

*1 岐阜大学大学院工学研究科
Graduate School of Engineering, Gifu University

*2 岐阜大学工学部
Faculty of Engineering, Gifu University

This paper produces a music recommendation system better than established systems. In this paper, we firstly discuss significance of music recommendation system. Secondly, we also discuss problems of conventional music recommendation. In order to overcome the problems and improve recommendation system, thirdly the aim of our research is established to develop an intelligent music recommendation system. Modelling of human information processing is then investigated, which idea comes from the formative model of receptive field in initial vision stage, and is different from those of traditional systems. And finally, a new music recommendation system is produced using the model.

1. はじめに

1.1 音楽推薦システムの意義

音楽推薦システムは、一般的に、情報の提供において個人への適応をはかり、大量のデジタルコンテンツの中から個人の望むものをすばやく検索・推薦するための情報システムである。しかし筆者は、音楽推薦システムをより大きな枠で捉えて、「より豊かな音楽生活をサポート・プロデュースするための情報システム」としてそれを考える。しかしこれには1つの明確な答えがあるものではない。したがって本稿では、音楽推薦の大きな目的を、人々の音楽嗜好の深まりと定め、それを支援する情報システムとして音楽推薦システムを考えていくことにする。

このような観点に立つと、音楽推薦システムとして利用されることの多い、従来の代表的なコンテンツ推薦システムである協調フィルタリング[人工知能学会]には、多くの課題点を指摘することができる。以下にそれを記す。

- ・無難でありがちな、つまらないおすすめしか提案できない
- ・なぜおすすめなのか理由がよくわからない
- ・気分や状況の変化を考慮せずおすすめは常に同じ
- ・おすすめの提案のみの機能
- ・etc

1.2 より良い音楽推薦システム創作への方針

このような多くの課題点を柔軟に解決し、さらに様々な可能性を含んだ音楽推薦システムを創作するにあたり、本稿では、知能的な音楽推薦システムをつくるという方針で望む。そこでまず、そのアプローチとして、ユーザプロフィールデータの処理における人間的な情報処理のモデル化を試みる。

2. 概念のモデル化による音楽推薦

2.1 部分的な共起特徴に着目したデータ認識

従来の代表的なコンテンツ推薦システムである協調フィルタリングでは、それぞれのコンテンツに対するユーザの与えた評価値であるユーザプロフィールに対して、その類似度(相関)にもと

づいた機械的で単純な計算を行う。しかしこのような数理モデルに基づいた音楽推薦システムは、先の課題点を本質的に解決できない。また相関などに基づいた多くのデータ分析は、人間的で複雑な要因のあるデータの分析には不適である。そこで、データ処理をするにあたり、データの人間的な認識を考え、図1のようなモデルを考える。



データの統計的な性質から生まれた概念により、データを認識する

図1 部分的な共起特徴に着目したデータの認識

図1のようにデータの部分的な共起特徴に着目してコンテンツ群の概念化を行い、その概念によりデータを認識する情報処理を、人間的な情報処理と考え、ヒトの初期視覚の受容野形成の数理モデルであるスパースコーディング[村田 03]の理論を応用してこの情報処理モデルを構築し、それにもとづく音楽推薦システムを創作する。

2.2 データ学習による概念形成

スパースコーディング[村田 03]は、初期視覚における、下位層からの信号の統計的な性質を利用して、上位層への情報の伝達を効率よく行うための、受容野形成の数理モデルである。本稿ではこれを効率の良い概念形成のモデルとみなし、以下にスパースコーディングを応用した音楽推薦システムの構築を説明する。

ユーザプロフィールは、コンテンツの支持を1、不支持または未知を0とする。システムは、サンプルデータ(あるユーザプロフィールデータ)を複数の基底(概念)の重ね合わせとして認識する。このとき評価関数 $E(\mathbf{a}, \phi)$

$$E(\mathbf{a}, \phi) = \sum_{p=1}^P \left\{ \left(I^p - \sum_{i=1}^n a_i^p \phi_i \right)^2 + \lambda \sum_{i=1}^n |a_i^p| \right\} \quad (1)$$

- I: あるサンプルデータ(ベクトル, 要素の値は0か1の離散値)
- ϕ : 基底(ベクトル, 要素の値は0以上1以下の連続値)
- a: 係数(0か1の離散値)
- n: 基底数
- P: サンプル数

を最小にする \mathbf{A} : 行列 \mathbf{a} の集まり と、 Φ : 行列 ϕ の集まり を、デ

連絡先: 西尾毅士,
岐阜大学 大学院 工学研究科 応用情報学専攻,
岐阜県岐阜市柳戸 1-1, E-mail: nishio@hym.info.gifu-u.ac.jp

ータ学習により求める。評価関数の1項目は残差をできるだけ小さく(再現性をよく)するための、2項目はできるだけ多くのaを0に近くする(スパース性)という条件になっている。λはその2つのバランスを決めるための定数である。つまり、効率の良い概念形成を学習により行うことになる。

学習アルゴリズム

1. まずΦに適当な初期値をあたえる
2. Φを固定し、評価関数により最適なAを求める
3. ΦとAからサンプルを再現し、実データとの残差をもとめる。そして残差を減少させる方向へΦを更新する
4. 2と3を、AとΦがともに変化しなくなるまで交互に繰り返す

数理モデルは本問題の性質に適するように、基底の重ね合わせを非線形合成(各基底の要素のうち最大の値を合成値とする、注) (1)の2つめのΣは便宜的な表現)、概念のユーザプロフィールへの属性である係数aは0か1の2値、と定める。3ではその残差を、使用している基底で補う形である(2)

$$\Delta\phi_i = \frac{1}{P} \sum_{p=1}^P \left\{ \frac{a_i^p}{\sum_{i=1}^n a_i^p} \left(I^p - \sum_{i=1}^n a_i^p \phi_i \right) \right\} \quad \text{--- (2)}$$

を計算し、微小なε>0をとり、

$$\phi_i \leftarrow \phi_i + \epsilon \Delta\phi_i$$

でΦを更新する。ここでεはφの学習率である。またφの要素の値は非負とする。

概念の重ね合わせを非線形合成とした理由は、概念の重ね合わせによるユーザプロフィールの再現のモデルを、非線形の場合がシンプルで自然であると考えたことによる。また線形合成の場合には、合成値が1を超えてしまおうと学習時に働くことが想定され、全体的な整合性のある適切な数理モデルが構築できないからである。

Φの初期値と基底の数は、概念の大きさ(基底の要素の値が大きいものの数が多いほど、それを大きい概念と呼ぶことにする。小さい概念の場合は、学習結果に、よりデータの局所性が反映されやすい)と、概念の共有(どれくらい多くのユーザプロフィールに属性をもつか)による、音楽推薦(後述)の局所性の反映と無難性のバランスを考慮し、現段階では経験的に値を決める。なお、この最適な基底の数の決定問題は今後の大きな課題点であるとする。

定数λは(1)の最尤推定の立場との関連から[村田 03]、学習率εは実験的な検討の結果から、値を決定する。

2.3 概念形成の詳細

収束状態であるΔφの大きさが0になる状況を考えてみる。Δφの大きさが0であるとは、

1. そのφを使用しているすべてのサンプルの誤差が0の場合、
2. そのφを使用しているすべてのサンプルの誤差を修正する方向が+のつりあいとれ均衡している状態

のどちらかである。1の場合は特に考慮する必要はないが、2の場合を考慮して、本手法の学習の様子を説明する。

非線形合成では、再現プロフィールの値を1にするにはどれか1つの使用基底の値が1であればよい。よってある基底の値が0であっても、他の使用基底の値によっては誤差なく1が再現されることもある。つまりこのような非線形合成をすることにより、各基底はどうしても自身が1でなくてはならない状況(統計的支持による値1のカバーの要求)が発生したときのみ、自身の値を上げる方向に学習がはたらく。その状況とは、値1をカバーすべきサンプルがあり、その基底が使用されたすべてのサンプルにおいて、誤差を修正しようとする学習する方向の総和がプラスにはたらい(その基底がその状況をカバーするように統計的に選択された)ときである。つまりそのような状況に無い場合には、基底は変

化しないか、他のサンプルの値0の要求に答え一方向に学習されるかのどちらかである。

このようにして収束した基底はそれぞれ、統計的に支持されたコンテンツ群のファジィクラスタリングの結果であるとみなすことができる。そしてスパース性を要求する(1)の第2項により本手法は、統計的に支持された、可能な限り大きなクラスターを求めることになるといえる。

2.4 想起にもとづく音楽推薦

本手法では、再現(想起)されたデータと実データとの誤差に着目して、音楽推薦を行う。例えば以下のような場合、

コンテンツ	a	b	c	d	e	f	g
再現プロフィール	0.5	1.0	1.0	0.0	1.0	0.0	0.7
実際のプロファイル	0.0	1.0	1.0	0.0	1.0	0.0	1.0
誤差	0.5	0	0	0	0	0	-0.3

図2 再現プロフィールと実際のプロファイルの誤差

変数aの誤差+0.5、変数gの誤差-0.3は、他ユーザと同じ基底を使用している状態で学習が収束した結果、誤差+は他ユーザからコンテンツを支持されている状況、逆に誤差-は他ユーザに支持している状況である。そのように誤差の解釈を行い、先述した学習の収束状態のバランスを考慮し、以下のようにまとめることができる。

- ・誤差++ 多くのユーザにすすめられている
- ・誤差+ 少数のユーザがすすめている
- ・誤差- 多くのユーザとともに誰かにすすめている
- ・誤差-- ユーザの特異な部分

このような音楽推薦は、システムのデータの認識による想起(再現)を利用したものといえる。




図3 同じモデルでデータの認識と想起を行うことになる

学習に要する計算時間は、現在の一般使用の計算機で、ユーザ数が100人程度、コンテンツ数が300程度の場合、各種パラメータの設定値にもよるが、繰り返し計算のため、数10秒程度要する。音楽推薦に要する時間は、一度のユーザプロフィールの認識とイメージプロフィールの想起であるので一瞬である。つまりWEB上などで、実利用の可能性のある音楽推薦システムであるといえる。

また、想起プロフィールの推薦コンテンツについて、その要素の値を結果的にもたらした概念の内容を、あわせてユーザに提示することで、そのコンテンツの推薦理由「このコンテンツaは、あなたがコンテンツb, c, dを好きだからおすすめです。」みたいなものを伴った音楽推薦が可能となる。

2.5 知識のバイアスを学習に用いる

より良い解(概念群)に収束させるために学習に知識を利用することを考える。本手法では、まず「有名度」、「重要度」という以下の図4のようなデータテーブルをつくる。

	a	b	c	d	e	f
Aさん	0.5	0.2	0.3	0.5	0.1	0.2
Bさん	0.5	0.2	0.3	0.5	0.1	0.9
Cさん	0.5	0.2	0.3	0.5	0.1	0.2

- ・有名度は各コンテンツで同じ
- ・重要度は各場所ごとに与える

図4 有名度・重要度テーブル

現段階では、「有名度」は、そのコンテンツを支持しているユ

ユーザの割合に比例した数値を用いる。「重要度」は、各ユーザに個別の各コンテンツそれぞれに対する数値であり、各ユーザからフィードバック(後述)を行うなどして与えるものとする。

そして、この「有名度」、「重要度」を知識として、その学習への利用方法について説明する。(1)(2)において残差計算を行う際に、その計算対象になる部分に対応した有名度・重要度のデータテーブルを参照し、そのテーブルの値に比例して残差計算を大小にみつめる。これをAを求める場合にもΦを更新する場合にも行う。その結果、Aを求める際には誤差項の計算結果に影響を与え、知識を踏まえたAを選択する方向に学習がはたらくことになる。Φの更新時には、更新の方向を強制することになる。このとき、学習率εはかなり小さいので、あくまで相対的な学習の方向を強制することになり、問題はない。

この結果、「有名なコンテンツほど評価値0のユーザにも既知である可能性が高く、そのようなコンテンツの評価値を相対的に信頼して(データ認識をして)学習する」といったような、複数の分析による、知識の反映された音楽推薦を行うことができる。なおこのことにより、有名ではないが、局所的に支持されたコンテンツを推薦するという、価値のありそうな音楽推薦を期待することができる。

また、ユーザからのフィードバック(例えばおすすめが失敗だった)を得ることで、その部分に「重要度」として非常に強いバイアスを与えると、収束していた状態から再学習を行うことができる。そして記憶を再構築し、新たに音楽推薦をすることができる。

このような知識利用の学習は、データの共起に基づく基本的な概念形成の過程において、より高次の思考が記憶の形成に働きかけるといった形のモデルとなっているとみなすことができる。

3. 評価実験

3.1 データを収集して実際に音楽推薦をおこなう

実際にデータを収集して評価実験を行った。今回はアンケートによるデータ収集をした。内容は、あらかじめ用意された邦楽・洋楽・クラシック・ジャズなど様々なジャンルから集めたアーティスト157のそれぞれに対し、被験者はそのアーティストにお気に入りの曲があるかないかを判断しチェックをする。これをチェックあり1、チェックなし0のユーザプロフィールデータとし、20人からデータ収集を行った。そして従来手法である協調フィルタリング[人工知能学会]と提案手法の、2つによる音楽推薦を被験者に行い評価してもらった。

評価項目は、本稿の始めにあげた課題点に関して、実際に音楽推薦をしたコンテンツの試聴を行ってもらうなど、長期的な使用を経てのユーザ評価を行うことは現実的に困難であるので、音楽推薦システムの使用の入り口段階における、今後の使用につながりそうな感性的な評価項目を用意した。音楽推薦の精度への期待感に関する評価、音楽嗜好の深まりにつながりそうな推薦スタイルへの評価(従来手法と提案手法の比較)、の5つの評価項目である。また感想などの自由記述も行ってもらった。

アーティスト単位での音楽推薦の理由を以下に述べる。より良い音楽推薦システムを目指すにあたり、ユーザによる評価値の入力負担の軽減を考える必要がある。そこでユーザの所有する楽曲ファイルの情報などを利用した、自動的なユーザプロフィールの作成を今後の視野にいれる。しかし、楽曲単位のユーザプロフィールをそのままシステムの入力データにすると、コンテンツの数が膨大になってしまう。またそのようなデータはスパース性が高く、概念を形成しデータの重なり合いを元に音楽推薦を行う本手法が本質的に機能しにくくなる。したがってアーティスト単位のデータに変換することで、データの重なり合いを確保す

る。そして概念形成の段階で自然と(共起しやすいコンテンツに差がでてきた場合には)、そのコンテンツを含んだ概念が複数生成されるなどし、重ねた楽曲群の分離のようなことも可能になる。それにより楽曲単位での適切な音楽推薦の可能性もみえてくる。

3.2 実験結果

以下、図5は学習の結果、実際に形成された概念の例である。図6, 7は実際にある被験者へ行った音楽推薦の例である。従来手法による音楽推薦(図6)と、提案手法による音楽推薦(図7)は元々は数値的なものであるが、それぞれの数理モデルの理論から妥当な、簡単な言語化ルールを用意し、そのルールに基づき文書化を行ったものである。このような文書により音楽推薦を行った。

概念1:	AI, AIKO, BUMP OF CHICKEN, MR.CHILDREN, RIPSPLYME, ケツメイシ, スキマスイッチ, ゆず, 山崎まさよし, 大塚愛, 椎名林檎,
概念2:	BOA, EXILE, 安室奈美恵, 倭田来未, 大塚愛, 浜崎あゆみ
概念3:	JUDY AND MARY, 大塚愛
概念4:	PUFFY, サザンオールスターズ, スピッツ, 小沢健二, 椎名林檎,
概念5:	GLAY, SMAP, ZARD, サザンオールスターズ, 宇多田ヒカル, 島谷ひとみ, 浜崎あゆみ, 平井堅, マライアキャリー
概念6:	JUDY AND MARY, the brilliant green, TUBE, 福山雅治, モーツァルト
概念7:	BUMP OF CHICKEN, MR.CHILDREN, くるり, レミオロメン
:	:
:	:

図5 実際に学習により形成された各概念(基底)の例(閾値で値の大きいコンテンツのみ選択表示)

・従来手法による音楽推薦

OOさんへ。音楽推薦Aです。
アーティストの右側の数値は、おすすめの数値です。

ケツメイシ	0.33
スキマスイッチ	0.32
ゆず	0.32
SMAP	0.29
山崎まさよし	0.29
椎名林檎	0.28
宇多田ヒカル	0.27
ORANGE RANGE	0.26
一青窈	0.26
コブクロ	0.25
EXILE	0.24
カーペンターズ	0.24
BENNIE K	0.23
BOA	0.23
GLAY	0.23
ブルーハーツ	0.23
浜崎あゆみ	0.23
平井堅	0.23
Do As Infinity	0.22
ウルフルズ	0.22

図6 実際にある被験者へ行った音楽推薦(従来手法)

・提案手法による音楽推薦

OOさんへ。音楽推薦Bです。

すごくおすすめです。: hide with spread beaver
もしかするとおすすめです。: the brilliant green, RIP SLYME, Do As Infinity

理由はOOさんは、これらのアーティストが好きだからです。:
JUDY AND MARY, 大塚愛

すごくおすすめです。: PUFFY, 小沢健二, 椎名林檎,
ブルーハーツ, 松任谷由実

理由はOOさんは、これらのアーティストが好きだからです。:
サザンオールスターズ, スピッツ

すごくおすすめです。: The Beatles,
もしかするとおすすめです。: Ellegarden, ASIAN KUNG-FU GENERATION, コールドプレイ

理由はOOさんは、これらのアーティストが好きだからです。:
BUMP OF CHICKEN, MR.CHILDREN, くるり, レミオロメン

図7 実際に同じ被験者へ行った音楽推薦(提案手法)

3.3 ユーザ評価




図8 従来手法のおすすめ精度についてのユーザ評価




図9 提案手法のおすすめ精度についてのユーザ評価




図10 従来手法と提案手法の比較についてのユーザ評価

以上, 図8, 9, 10は, 音楽嗜好の深まりに関して設定した5つの評価項目における, 20人の被験者の, 提案手法と従来手法の音楽推薦についての評価の集計結果である. 提案手法は従来方法と比較し, 用意した5つの評価項目のすべてにおいて, 多くの被験者から高い評価を得ている.

4. 考察

提案手法が従来手法と比較して, 優れたユーザ評価を得ることが出来た理由は, 被験者の各種の評価結果の集計と自由記述の考慮から, 主に3点にまとめられる. 複数に分けられた理由付きの音楽推薦が評価された点, データの局所情報をとらえた音楽推薦に情報的な価値があると評価された点, 知識などの利用による複数のデータ分析を統合した精度のよい音楽推薦であった点である. 実際に知識を用いた学習は, 知識を用いない場合の学習と比較し, 学習結果に大きな違いをもたらすことが確認された. 今後, 現段階での「有名度」などの単純なデータ分析だけでなく, より高次的なデータ分析や, web などからの良い情報収集や, 実際にユーザからのフィードバックを行うなどの知識の獲得により, 結果はさらに向上していくことが期待される.

これらの利点はすべて, 人間的な情報処理をモデル化したことにより, もたらされたといえる.

各種パラメータの設定については, 今回は経験的に良いと思われる値決めを, 主観的に行った. 各種パラメータの値により, 概念の形成は傾向を見せながら変化する(先述2.3)が, おそらく1つの正解はないものだろうと筆者は考える. したがって希望するような解に応じて適切に値決めを行う必要があると考える.

5. 展望

本手法の音楽推薦は, 情報処理システムとして, 認識システムを想起システムとして用いた直感的な知能といえる. 入力データに対し記憶との照らしあわせを行い認識を行う. その認識結果に基づいてイメージとしてのデータを想起する. その想起により外界への行動(音楽推薦)を判断し出力を行う. 学習過程は記憶の更新である.

現段階では, 本手法は音楽情報処理の観点から[Pachet 03], 楽曲の信号などのコンテンツの内的な情報は用いず, コンテン

ツの外的な情報のみを用いていた音楽推薦システムである. より人間らしい情報処理を考えるならば, 音楽の信号情報などもあわせて用い, それらを統合的に情報処理を行う, 人間的な音楽環境全体の理解を目指すことが望ましい.

6. 結論

本稿では, より良い音楽推薦システムへ向けて, 音楽推薦システムの意義を議論し, 従来のシステムの課題点をあげ, 知能的な音楽推薦の必要性和, 人間的な情報処理のモデル化による音楽推薦システムを創作した. そして高いユーザ評価を得た. また提案手法から発展可能な方向を見出した.

今後の課題と方針を以下に述べる. ユーザフィードバック後の推薦精度の向上の検証, 3.1で述べた楽曲群の分離に関する検証, WEB上での実利用における検証, より人間的な情報処理(学習への知識のダイナミックな働きかけ, 様々な知識の形成, コンテンツの内容に基づく情報の抽出と, それらの統合的な情報処理), 音楽推薦・検索のためのより良いインターフェースの設計, などである.

参考文献

- [人工知能学会] 人工知能学会 Website: What's AI
人工知能の話題 協調フィルタリング
<http://www.ai-gakkai.or.jp/jsai/whatsai/AItopics2.html>
- [村田 04] 村田昇: 独立成分分析, 東京電機大学出版局, pp.205-229, (2004).
- [Pachet 03] Francois Pachet: communications of the ACM. Vol. 46. No. 4, (2003).
日本語訳) 北原鉄朗: デジタル音楽配信のためのコンテンツ管理, ACM Japan Chapter,
<http://www.acm-japan.org/CACMJ/4-2.html>
- [水口 05] 水口充: ペットメタファをもつ音楽プレイヤー, 第46回プログラミングシンポジウム, pp. 129-138, (2005).
- [後藤 04] 後藤孝行 後藤真孝:
Musicream: 楽曲を流してくっつけて並べることのできる新たな音楽再生インタフェース, 日本ソフトウェア科学会 第12回インタラクティブシステムとソフトウェアに関するワークショップ 論文集, pp. 53-58, (2004).