

ハイブリッド型音楽推薦システム

吉井 和佳[†] 後藤 真孝[†] 奥乃 博

(奥乃グループ：京都大学大学院情報学研究科奥乃研究室)

[†]産業技術総合研究所

概要 本稿では、「楽曲に対するユーザの評価」と「楽曲の音楽内容」とを同時に考慮できるハイブリッド型音楽推薦システムについて述べる。我々は開発当初より実用化を念頭におき、システムが備えるべき六つの要件 1. Accuracy, 2. Diversity, 3. Coverage, 4. Promptness, 5. Adaptability, 6. Scalability を設定した。従来の音楽推薦技術はユーザの評価か音楽内容か一方しか推薦に利用せず、要件 1. ~ 3. に関して一長一短があった。そこで我々は、両方のデータを確率モデルに基づいて統合することで、それらの要件を同時に満たすだけでなく、要件 4. も併せて解決できた。さらに、推薦精度をほとんど低下させることなく確率モデルの学習コストを大幅に削減することに成功し、要件 5 および 6. も解決した。実験の結果、推薦精度に関しても従来定評のあった手法と同等以上を達成することを確認した。

キーワード：音楽推薦、ハイブリッド型フィルタリング、パーソナライゼーション。

1. はじめに

現代の情報産業においてパーソナライゼーション技術は極めて重要である。iTunes Music Store などのインターネットを通じた音楽配信サービスは、数百万曲規模のデータベースを運用している。それらの中で各ユーザが聴くのはほんの一部であるが、全ユーザを集めれば大量に存在する知名度の低い楽曲(テール)は少数のヒット曲(ヘッド)と同じくらい聴かれている。これはロングテール効果と呼ばれ、ユーザの嗜好は極めて多様性に富むことを示している。そのため、ユーザの音楽的嗜好をシステムが自動的に推測し、それらに合った楽曲を推薦する技術が望まれている。

本研究ではまず、音楽推薦システムを実用化する上で重要な六要件を以下に掲げる。

1. Accuracy: 精度よく推薦できる
2. Diversity: 多様なアーティストが推薦できる
3. Coverage: 未評価の楽曲も推薦できる
4. Promptness: 迅速に推薦できる
5. Adaptability: データ変化に対応できる
6. Scalability: 大規模データに対応できる

以降、従来の推薦技術を振り返りながら、このような六要件を同時に満たす推薦システムを開発するための方法を述べる。

2. 従来の音楽推薦技術

本章では、従来の音楽推薦技術についてそのコンセプトとアルゴリズムの観点から説明する。

2.1 推薦コンセプト

従来の音楽推薦技術は、その推薦コンセプトにより「協調フィルタリング」と「内容に基づくフィルタリング」とに大別でき、表 1 に示すように相補的な特徴を持っている。

協調フィルタリングは他のユーザがどのように楽曲を評価したのかを参考にして推薦を行う集合的アプローチであり、商用サービス (Last.fm や Amazon.com など) ですでに成果を挙げている [1]。

	評価ベース	内容ベース
1. Accuracy	○	×
2. Diversity	×	○
3. Coverage	×	○

表 1 評価ベースと内容ベースの推薦手法

	メモリベース	モデルベース
4. Promptness	×	○
5. Adaptability	○	×
6. Scalability	△	×

表 2 メモリベースとモデルベースの推薦手法

しかし、多くのユーザは最頂の少数の人気アーティストにばかり高評価を与える傾向があるので、推薦されるアーティストのバラエティは乏しくなりやすい。また、未評価の楽曲は推薦できない問題がある (cold-start problem)。

一方、内容に基づくフィルタリングは音楽的要素や属性に基づいて推薦を行うアプローチである。利用する内容情報は、計算機により音楽音響信号から自動的に抽出される [2]、あるいは人手で与えられる。例えば、音楽配信サービス Pandora では、専門家が数百種類の内容タグを付与している。Last.fm では、ユーザが自由にタグ (social tag) を編集できるという集合的的手法を採用している。内容に基づくフィルタリングでは協調フィルタリングの抱える問題は存在しないが、文化的影響や市場での人気を考慮できず、十分な推薦精度が得られないことがある。

テキストを対象とした推薦システム分野では、各アプローチの弱点を克服するため、ユーザの評価とテキストの内容とを考慮するハイブリッド型フィルタリングの研究が盛んになってきている。しかし、実質的な研究目的は推薦精度の改善であり、その他の要件はほとんど考慮されていないのが実情である。また、音楽や映画を対象とする場合には、それに付随するテキスト (レビュー文など) から内容情報を抽出しており、推薦対象を直接解析することはしていなかった。

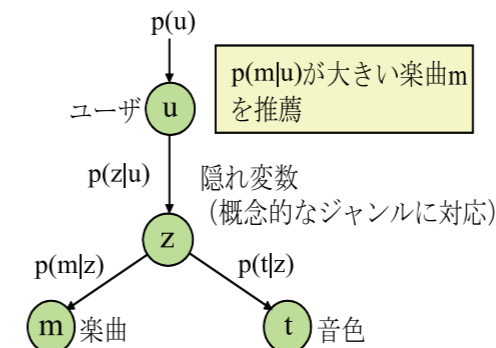


図 1 Three-way Aspect Model

2.2 推薦アルゴリズム

推薦アルゴリズムの観点からは、メモリベースのものとモデルベースのものに大別でき、それぞれ表 2 に示すような相補的な特徴を持っている。

メモリベースの推薦手法は、ユーザの推薦要求があるたびにデータを全て走査する。そのため、毎回の推薦に時間がかかるが、データが変化しても特別な対応は必要ない。一方、モデルベースの推薦手法は、推薦要求がある前に何らかのモデル (確率モデルが多い) を学習しておき、それに基づいて推薦を行う。そのため、一旦モデルが学習されれば推薦は迅速に行えるが、データが変化するたびにモデルを学習しなおす必要がある。また、データサイズが大きくなるほど評価がスパースになり、モデルを過学習しやすいため、スケーラビリティの問題がより深刻である。

3. ハイブリッド型音楽推薦システム

1 章で述べた音楽推薦システムを開発するため、我々は Popescul らが提案した Three-way Aspect Model と呼ばれる確率モデルに基づくハイブリッド型フィルタリング手法 [3] に着目する。以降、上記確率モデルについて解説し、音楽推薦に適用する際の問題点と解決法について述べる。

3.1 Three-way Aspect Model

図 1 に Three-way Aspect Model を示す。このモデルは、ユーザがある特徴をもつ楽曲を聴くという事象の発生メカニズムを確率的に説明する。まず、あるユーザ u が確率 $p(z|u)$ でジャンル z を選択する。次に、確率 $p(m|z)$ で楽曲 m が、確率 $p(t|z)$ で特徴 t が観測される。すなわち、ユーザの嗜好は $p(z|u)$ として直接表現される。ここで、ジャンルとは理解を助けるための便宜的な解釈であることに注意されたい。推薦に利用するデータは、ユーザ・楽曲のペアからなる評価、楽曲・特徴のペアからなる音楽内容であり、ジャンルは観測することができない隠れ変数である。このような場合にそれぞれの確率値を学習するには、EM アルゴリズムを利用する。モデルの学習が終われば、 $p(m|u)$ の大きいものからランキングすればよい。

3.2 問題点

上記目的で Popescul らの手法を利用するには以下の三つの問題を解決しなければならない。

1. Adaptability の欠如: モデルベースの手法は Promptness に優れる一方、Adaptability で劣る。あるユーザが評価を変えた場合、それに即座に対応することができないうえ、新規ユーザや新規楽曲を逐次的に追加登録していくこともできない。そのため、確率モデル全体を毎回再学習する必要がある。
2. Scalability の欠如: 確率モデルの学習時間はユーザ数と楽曲数に比例するため、巨大なデータを扱うことが難しい。また、ユーザの評価が極めてスパースになると、モデルの汎化性能が著しく低下する。
3. 音楽音響信号に適用不可能: Popescul らの手法はテキストを対象としたものであり、テキストの一般的な内容表現として Bag-of-Words モデルを利用することを想定している。しかし、音楽音響信号にはそのような表現方法は存在しない。

3.2 解決法

上記三つの問題を解決するため、我々は以下の三つの解決法を提案する。

1. インクリメンタル学習法: データ変化に関係した部分のみを逐次的に更新する。新規ユーザ (評価を変更した既存ユーザ) u' が追加された場合は、既存の $p(m|z)$, $p(t|z)$ を用いて $p(z|u')$ だけを推定すればよい。新規楽曲 m' が追加された場合も、 $p(u|z)$, $p(t|z)$ を固定して $p(m'|z)$ を推定するだけでよい。
2. クラスタに基づく学習法: あらかじめユーザと楽曲を評価の付け方と音楽内容によってそれぞれグルーピングしておき、一定数のグループの代表ユーザ・楽曲のみでコンパクトなモデルを学習する。その後、インクリメンタル学習法を用いて全ユーザ・楽曲を追加登録する。
3. Bag-of-Features モデル: 楽曲データベース全体の特微量分布に対して、混合ガウス分布を学習する。得られた要素分布の平均と分散は固定し、各楽曲の特微量分布に対して重みのみを推定する。各楽曲から得られた重みベクトルは、テキストの単語頻度ベクトルと同様に扱うことができる。

4. おわりに

提案した音楽推薦システムは 1 章で述べた六要件を同時に満たすだけでなく、従来定評のあった Aspect Model に基づく協調フィルタリング手法と同等以上の推薦精度を達成した。今後はベータテストを通して被験者実験を行っていききたい。

参考文献

- [1] Breese, J. et al.: Empirical Analysis of Predictive Algorithms for Collaborative Filtering, UAI (1998).
- [2] Hoashi, K. et al.: Personalization of User Profile for Content-based Music Retrieval based on Relevance Feedback, ACM Multimedia, pp.110-119 (2003).
- [3] Popescul, A. et al.: Probabilistic Models for Unified Collaborative and Content-based Recommendation in Sparse-data Environments, UAI (2001).