

楽曲宣伝のターゲット決定のためのユーザ推薦システム*

高橋 滉弥[†], 伊藤 克亘[‡]

1 まえがき

楽曲推薦システムを導入しているサービスは多数存在しているが、推薦された楽曲がユーザの心に響かない場合がある。本研究では、楽曲推薦の際にターゲット層を限定できるような、楽曲に対するユーザ推薦システムを提案する。ユーザの嗜好の予測には、ユーザが好む曲が複数含まれている100万のプレイリスト、のべ6000万曲を用いて行う。プレイリストを用いることで嗜好のパターンをわかりやすく表現できるが、曲数が膨大なため情報が疎らである。本研究では、楽曲の特徴量と行列因子分解を組み合わせたハイブリッド型フィルタリングにより評価値行列を作成し、推薦を行う。

2 プレイリストを用いた推薦システム

本研究ではプレイリストを用いてユーザの嗜好を考える。プレイリストには、ユーザが好む楽曲が複数含まれているため、プレイリスト全体を通して共通点が存在すると考える。プレイリストの自動生成とその評価について行われている研究[1]では、プレイリスト生成のための戦略や必要な情報についてまとめられている。この研究により、プレイリストは何かしらの特徴を持ち、楽曲の出現パターンやプレイリスト内のメタデータなどを含む特徴の類似性が推薦システムに活かすことができるという利点を持っていることがわかっている。しかし、プレイリストが持つ欠点として、ユーザはプレイリスト内の楽曲を気に入っていると直感的に考えられるため、これらの情報からはユーザのマイナスの評価を確認することができない。

本研究では、楽曲宣伝のためのターゲット層の限定化が目的であるため、ユーザのマイナスの評価は使用せず、好みの楽曲の情報のみを扱う。よって、プレイリストから得られるユーザの好みの特性を膨大なデータ数から知ることで推薦のターゲット層を絞り込む。

3 提案手法

提案するシステムの概要について説明する。まず最初に、100万のプレイリストが含まれる訓練データを用意し、そのプレイリスト内の各楽曲の特徴量を求める。求められた特徴量から、膨大な数の楽曲はクラスタリングにより複数のカテゴリに分類される。また、プレイリストに入っている楽曲情報からスパース行列を作成し、特異値分解によりプレイリストの行列は次元削減が行われ、低次元の行列で表現される。完成したプレイリストと楽曲の2つの低次元行列の積によって評価値を予測し、その数値を基にユーザの嗜好を予測する。最後に、推定された嗜好を基に推薦されるべきユーザを選択し、出力する。推薦されるべきユーザは1

人に限定されることはないため、該当する複数のユーザを出力する。

プレイリストを用いたユーザの嗜好をまとめた行列は[2]、[3]のように定義する。m個のプレイリストが与えられ、それぞれがn個の曲の一部を含んでいるとする。プレイリストiに曲jが含まれていれば $C_{ij} = 1$ 、そうでなければ0とする行列 $C \in \{0,1\}^{m \times n}$ を作成する。これは、行列の要素の99.9%は0で構成されるスパース行列となる。プレイリストを用いて集められたユーザの嗜好情報は、視聴履歴を用いた場合に比べて遥かにスパース性が高く、推薦の精度が低い。そこで、行列因子分解やクラスタリングにより、スパース行列Cをプレイリストと楽曲の2つの行列A,Bに分解する。これにより、プレイリストに含まれる楽曲の情報から、他楽曲に対する評価値の予測を行う。どのプレイリストにも含まれていない新曲が入力された場合は、最初はユーザの評価がなく評価値が全て0となってしまう行列分解によって正しい評価値予測ができないが、クラスタリングを行った後の楽曲についての行列内で学習を行うことで、他楽曲の中から類似している楽曲を探すことができる。

本研究では、膨大な数のプレイリスト、楽曲を扱う。そのため、プレイリストや楽曲同士の類似度を学習するにあたり、相関があまりないデータが多く存在すると、学習に時間がかかるだけでなくそのデータがノイズとなって出現してしまう。すると、関係ない情報として干渉してしまい、システムの性能を下げる原因となってしまう。そこで次元削減をすることにより、とても大きなサイズの行列も、低次元の主要な特徴量を持ったデータとして扱うことができるようにする。

次元削減の手法として、特異値分解(SVD)や主成分分析(PCA)などが存在する。本研究では、膨大なサイズのスパース行列を特異値分解することによりプレイリストの低次元行列を求める。また、データセットから入手した楽曲をクラスタリングする際にも、楽曲の特徴量に対して主成分分析を行う。

4 実験

本研究では、ユーザがよく聴く複数の楽曲からユーザの特徴量の決定ができるという観点から、プレイリストを採用する。プレイリストの訓練データとして、「Spotify Million Playlist Dataset」を用いる。これは、音楽推薦の研究のために用意されたデータセットであり、100万のプレイリストが含まれている。1つのプレイリストには約50曲の楽曲が含まれており、全体で延べ6000万曲の情報で構成されている大きなデータである。これらのプレイリストは、音楽ストリーミングサービス「Spotify」内での公開プレイリストからサンプリングされたものである。このデータセットはトラック、アルバム、アーティストの名前やURIで構成されている。

*: A user recommendation system for targeting music promotion Koya Takahashi (Hosei Univ.) et al.

[†]法政大学 情報科学部

[‡]法政大学 情報科学部

4.1 楽曲特徴量

楽曲の特徴量は、Spotipy というライブラリを用いて、Spotify Web API のデータに接続し、取得する。本研究で扱う特徴量は、表 1 で示す 11 次元の特徴量である。主成分分析により 4 次元まで特徴量を落とし、4 次元の特徴量によって楽曲のクラスタリングを行う。

表 1. 取得される楽曲特徴量

acousticness	楽曲のアコースティック感
danceability	リズムの安定性、ビートの強さに基づく値
energy	強度と活動性の知覚的な尺度
instrumentalness	楽曲にボーカルが含まれていないかの予測
liveness	レコーディング中の観客の存在を検出
loudness	楽曲の全体的な物理的な強さ (db)
speechiness	楽曲に含まれる話し言葉の存在を検出
mode	楽曲の調
valence	音楽的なポジティブ度
tempo	楽曲の BPM
time signature	楽曲の拍子

4.2 行列 C の作成方法

行列 C は、プレイリスト i に曲 j が含まれていれば $C_{ij} = 1$ 、そうでなければ 0 とする行列 $C \in \{0,1\}^{m \times n}$ である。データセットを参照して全曲の ID に番号を振った辞書を作成し、そこから辞書に存在する楽曲の行列番号を列挙することでスパース行列を作成していく。

データセットのプレイリストは全部で 1000000 個、楽曲数は重複しているものを除くと全部で 2262292 曲である。よって、この手順により作成される行列 C は 1000000×2262292 のスパース行列となる。

4.3 行列 A,B の作成方法

行列 A,B は、プレイリスト間の距離や曲の類似度を表す低次元の行列である。行列 A,B はそれぞれ、特異値分解やクラスタリングによって次元削減が行われることで完成する。 1000000×2262292 のスパース行列 C を特異値分解し、特異値が大きい順番にプロットすると図 1 のようになる。特異値は $k=50$ 近辺までは急激に減少し、 $k=50$ 以降は緩やかに減少し続けるような値を取っていることがわかる。これより、 $k=50$ で特異値分解を行い生成された 1000000×50 の行列 A、 50×2262292 の行列 B の積で、元のスパース行列 C に近い行列を表現できるといえる。

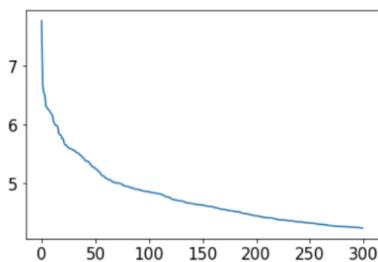


図 1. 特異値の推移の様子

4.4 楽曲のクラスタリング

Spotify により提供されている特徴量を用いて楽曲のクラスタリングは行われる。まず、11 次元の特徴量を主成分分析により 4 次元まで落とす。特徴量を正規化

し、累積寄与率を確認すると図 3 のようになる。第 1 主成分の寄与率は 40% であり、第 4 主成分までで元の特徴量の 80% 以上を表すことができている。この 4 次元の特徴量を用いて、1 回しか登場しない楽曲を除外したおよそ 100 万曲をクラスタリングし、50 個のクラスターに分類した。データセット内の全ての楽曲は、50 パターンのいずれかのカテゴリに分類される。

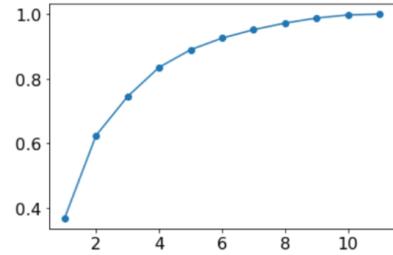


図 2. 各主成分の累積寄与率

5 予定実験

提案した手法の有効性を確認するため、評価実験を行う。訓練データとして用意したプレイリストから頻出する楽曲を数曲抜き出し、それらの楽曲を入力としてシステムを動かす。まず、入力楽曲を除いた楽曲でクラスタリングを行い、入力楽曲に近いクラスターを見つける。そこから入力楽曲に類似した楽曲を数曲抜き出し、その楽曲の情報が含まれる行列によって評価行列を再構成する。最後に、入力楽曲が元々含まれていたプレイリストを保有するユーザが出力結果として表示されることを確認する。

データセット内で 1000 回以上出現している楽曲をランダムで抜き出し入力とした時、その楽曲をプレイリストに含んでいるユーザが出力される割合を正答率とすると、1% 程度となった。この結果は、従来研究の手法と比べるととても低い精度である。

6 あとがき

本研究で提案した手法によって、入力楽曲に対するターゲット層を全体の 10% 選択し、提示することができた。しかし、評価実験により性能を確認すると、従来研究よりも良い結果を残すことができなかった。今後は、プレイリストの性質をより一層補うような手法を提案し、性能を改善していきたい。

参考文献

- [1] G.Bonnin et al., "Automated Generation of Music Playlists: Survey and Experiments", ACM Computing Surveys, Vol.147, Issue.2, No.26, pp.1-35.
- [2] K.Benzi et al., "Song recommendation with non-negative matrix factorization and graph total variation", IEEE International Conference on Acoustics, Speech and Signal Processing, 2016, pp.2439-2443.
- [3] S.Rendle, "BPR: Bayesian Personalized Ranking from Implicit Feedback", Proceedings of Conference on Uncertainty in Artificial Intelligence, 2009, pp.452-461.