

好みの時間的変化を考慮した推薦に関する研究

Recommendation Based on Preference Prediction

犬塚 健太 *¹ 高木 友博 *²

Kenta Inuzuka Tomohiro Takagi

*¹明治大学理工学研究科基礎理工学専攻

Department of Computer Science, Meiji University

Recent studies have shown that incorporating context data such as weather, time, and location in recommender systems improves the accuracy of the recommendation. In this paper, we focus on the ordering of the time to analysis changes in user preferences. We aim to improve the accuracy of the recommendation by learning the ordering of user's purchasing data by using the Kalman filter. Experimental results on Last.fm, which is the music dataset, verified efficiency of our approach compared to the comparative approach such as the Simple Markov process.

1. はじめに

近年、インターネットの普及に伴い、人々は容易に多くの情報に触れることが可能になった。その膨大な情報の中から人々にとって有用な情報を取捨選択することは困難であるため、各ユーザーに適した情報を提供する方法の一つとして「情報推薦システム」が注目されている。

我々が生活を行う際、身の回りには天気、時間、場所などの様々な要素が付随している。そして、これらの要素により人々の好みは変化する。よって、これらの要素を推薦システムに組み込むことは有用と考えられる。本稿では特に、時間による好みの変化に着目して研究を行う。

本研究では、ユーザーの購買履歴の順序性を、カルマンフィルターを用いて学習することで、推薦精度を向上させる試みを行う。音楽の試聴データである Last.fm を用いて推薦精度の比較評価を行った結果、単純マルコフ過程などの従来手法に比べ、提案手法がより精度が高いことを確認した。

2. 関連研究

2.1 時系列を用いた推薦

奥ら [奥 2009] はユーザーの好みを捉えるため、ユーザーの置かれている状況（以降、ユーザーコンテキスト）の順序性を考慮している。ユーザーコンテキストの順序性の抽出にはシーケンシャルパターンマイニング手法や LCS 抽出手法などを用いており、抽出されたパターンをもとに、ユーザーが次に取る行動を予測する。

Zhang ら [Zhang 2015] はユーザーの行動ではなく、レビューに存在する単語の出現回数をもとに好みの変化を考慮している。Zhang らはレビューの単語の出現回数を 1 日ごとに合計し、単語の出現回数の変化を 1 年周期でフーリエ変換と ARIMA モデルを組み合わせた FARIMA モデルを用いて定式化している。これにより、ユーザー全体の製品レベルの好みの変化ではなく、特徴レベルの好みの変化を考慮した推薦を可能にしている。

2.2 Weighted Regularized Matrix Factorization

行列因子分解は、ユーザーとアイテムを結びつけている潜在因子を見つけ出す手法として、情報推薦システムに広く用いられている。行列因子分解は、ユーザー自身がアイテムに対して評価を与える明示的なフィードバックのデータセットに対して有効である。例えば、MovieLens がこれにあたる。対して、暗黙的フィードバックのデータセットも存在する。これは、ユーザーの試聴回数や閲覧回数が記録されているデータセットであり、ユーザー自身がアイテムに対して評価を与えない。例えば、Last.fm がこれにあたる。本研究では、比較実験のためのデータセットとして Last.fm を用いている。そのため、通常の行列因子分解を使用できない。本研究では暗黙的なフィードバックに対して行列因子分解を行うことができる Weighted Regularized Matrix Factorization（以降、WRMF）[Hu 2008] を用いる。

ユーザー数を N 、アイテム数を M としたとき、ユーザー集合を $U = \{u_1, \dots, u_N\}$ 、アイテム集合を $I = \{i_1, \dots, i_M\}$ とする。WRMF は、ユーザー $u \in U$ がアイテム $i \in I$ を r_{ui} 回試聴した場合、 r_{ui} を以下の 2 式を用いて p_{ui}, c_{ui} に変換する。

$$p_{ui} = \begin{cases} 1 & (r_{ui} > 0) \\ 0 & (r_{ui} = 0) \end{cases} \quad (1)$$

$$c_{ui} = 1 + \alpha r_{ui} \quad (2)$$

ユーザーベクトル x_u 、アイテムベクトル y_i は式 (1), (2) で求めた p_{ui}, c_{ui} を用いて式 (3) を満たすように学習を行うことができる。

$$\min_{x_*, y_*} \sum_{u, i} c_{ui} (p_{ui} - x_u^T y_i)^2 + \lambda (\sum_u \|x_u\|^2 + \sum_i \|y_i\|^2) \quad (3)$$

さらに、ユーザー u のアイテム i に対するスコア \hat{p}_{ui} は以下の式を用いて算出する。

$$\hat{p}_{ui} = x_u^T y_i \quad (4)$$

連絡先: 犬塚健太, 明治大学理工学研究科基礎理工学専攻,
〒 214-8571 神奈川県川崎市多摩区東三田 1-1-1,
inukenta@cs.meiji.ac.jp

3. 提案手法

本研究では、ユーザーの購買アイテムから特徴量を抽出しその順序性を学習することでユーザーの好みの変化を考慮した推薦を行う。提案手法の概要図を図1に示す。

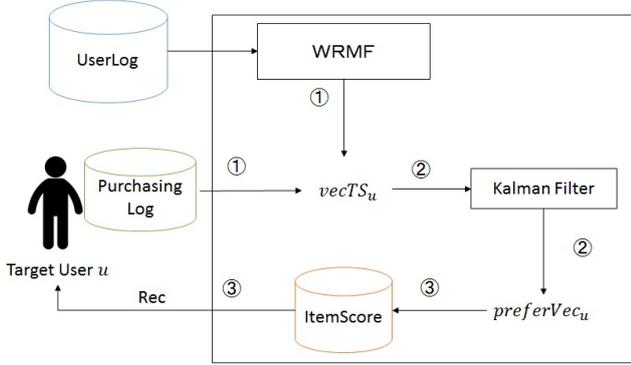


図1: システムの概要図

以降本章では、図1に沿って提案手法の説明を行う。

3.1 特徴量の抽出

ターゲットユーザー $u \in U$ の購買アイテム (Purchasing Log) からベクトルの時系列 $vecTS_u$ を抽出する。図1においては①の処理にあたる。

Purchasing Logには、ターゲットユーザー u が購買したアイテムのIDと購買した時間のタイムスタンプが紐づけられたデータが記録されている。タイムスタンプをもとにターゲットユーザー u の購買アイテムを時系列に並び替える。

次に、全てのユーザーの購買ログ (UserLog) をWRMFを用いて、 $N \times k$ のユーザー行列と $k \times M$ のアイテム行列に分解する。そして、アイテム行列を用いて、ターゲットユーザー u の購買アイテムを k 次元のアイテムベクトルとして扱う。これにより、 $vecTS_u$ を得ることができる。

3.2 ユーザーの好みの変化の考慮

$vecTS_u$ から好みの変化を考慮し、ターゲットユーザー u の好みを表すベクトル $preferVec_u$ を予測する。図1においては②の処理にあたる。本研究では、好みの変化を考慮するための手法としてカルマンフィルターを用いる。カルマンフィルターは、直接システムの状態が観測できない問題に対して適用されるため、ユーザーの好みの変化をとらえるための手法として適していると考えられる。カルマンフィルターは以下の2式で表せる。

$$In(t) = F(t)In(t-1) + v(t) \quad (5)$$

$$z(t) = H(t)In(t) + w(t) \quad (6)$$

式(5)は状態方程式と呼ばれており、システムの内部状態を表している。式(5)は、時刻 t の状態ベクトル $In(t)$ への変化を1つ前の状態である時刻 $(t-1)$ の状態ベクトル $In(t-1)$ とシステムの時間遷移を表す行列 $F(t)$ の内積にシステムノイズベクトル $v(t)$ を加えることで表現できる。

式(6)は観測方程式と呼ばれており、システムの状態をもとに観測値 $z(t)$ を出力する。 $z(t)$ は、時刻 t の状態ベクトル

$In(t)$ と状態ベクトルから観測ベクトルへの写像を表す行列 $H(t)$ との内積に測定ノイズベクトル $w(t)$ を加えることで表現できる。

式(5),(6)のノイズは正規分布によって表現され、それぞれ $v(t) \sim N(0, Q_t), w(t) \sim N(0, R_t)$ で表せる。実験の際、正規分布は標準正規分布を用いた。

本研究では各ユーザーを1つのシステムとみなすことでカルマンフィルターを適用し、ユーザーはアイテムの購買以外からの影響による好みの変化はないとする。この際、 $(t-1)$ から t の遷移はアイテムの購買の遷移とする。よって、 $vecTS_u(t)$ はターゲットユーザー u が t 番目に買ったアイテムのベクトルとなる。ターゲットユーザー u の好みは式(7),(8)を用いて予測される。

$$In_u(t) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} In_u(t-1) + v_u(t) \quad (7)$$

$$vecTS_u(t) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} In_u(t) + w_u(t) \quad (8)$$

式(7),(8)に $vecTS_u$ を入力することで、ターゲットユーザー u の好みを初めの購買から追跡することができ、 $preferVec_u$ が得られる。

3.3 アイテムの推薦

カルマンフィルターを適用することで、 $preferVec_u$ が得られた。このベクトルを用いて、アイテムの推薦を行う。図1においては③の処理にあたる。提案手法としてアイテムベース手法とユーザーベース手法の2手法を提案する。

アイテムベース手法は $preferVec_u$ とアイテムベクトルとの類似度を測り最も類似度の高いアイテムを推薦する。類似度手法はコサイン類似度を用いる。 $preferVec_u$ をアイテムベクトルとみなし、計算を行うため、アイテムベース手法と呼ぶことにする。

ユーザーベース手法は $preferVec_u$ とアイテムベクトルをWRMFのスコア算出式である式(4)と同様に計算を行い、スコアの最も高いアイテムを推薦する。 $preferVec_u$ をユーザーベクトルとみなし、計算を行うため、ユーザーベース手法と呼ぶことにする。

4. 実験

4.1 実験環境

実験では、Last.fm1Kデータセットを用いる。本データセットは、2005/2/14~2009/6/19の約52か月間のユーザーの音楽の試聴データを記録したものである。本データセットを図2のように分割し、4種類のデータを作成した。実験では、訓練期間とテスト期間それぞれで50回以上の音楽を試聴したユーザーのみ実験対象としている。データの規模は表1のとおりである。

実験ではTop-N推薦を行い、MAPとPR曲線による2種類の評価を行う。推薦数は $recItems = 50$ で行う。比較手法は、WRMF、単純マルコフ過程、人気順の3つとする。

表 1: データセットの規模

	訓練期間	テスト期間	ユーザー数	アイテム数
data1	2015/02/14~2008/02/14(36month)	2008/02/15~2008/06/14(4month)	574	238,332
data2	2015/02/14~2008/06/14(40month)	2008/06/15~2008/10/14(4month)	598	259,060
data3	2015/02/14~2008/10/14(44month)	2008/10/15~2009/02/14(4month)	644	279,060
data4	2015/02/14~2009/02/14(48month)	2009/02/15~2009/06/19(4month)	658	253,544

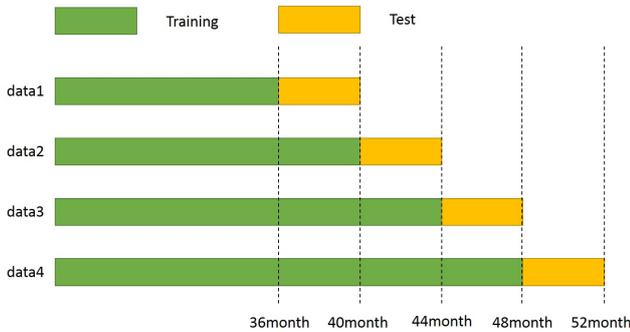


図 2: データセットの分割

行時間のバランスが最良である分解次元数 $k = 50$ を採用し、実験を行うこととした。

4.3 MAP による評価

比較手法と提案手法の比較を行う。MAP により、 $recItems = 1, \dots, 50$ の全ての推薦数の精度を考慮した実験結果を考察する。評価結果を表 4 に示す。

表 4: 比較手法との MAP による評価

	data1	data2	data3	data4	Average
WRMF	0.01408	0.01381	0.01306	0.01257	0.01338
単純マルコフ過程	0.01558	0.01469	0.01518	0.01907	0.01613
人気順	0.00571	0.00549	0.00648	0.00644	0.00603
ユーザーベース手法	0.01949	0.01803	0.01765	0.02065	0.01895
アイテムベース手法	0.03400	0.03239	0.02789	0.03396	0.03206

4.2 WRMF のパラメータ設定

比較手法との実験を行う前に、WRMF の分解次元数 k の設定について考察を行った。考察は、 $k = 20, 50, 100$ の 3 種類の次元数で行う。3 種類の次元数に対して、MAP による精度評価と実行時間の計測の 2 種類の評価を行った。2 種類の評価結果から考察を行い、最良の次元数 k を見つける。実験はアイテムベース手法に対して行った。評価結果を表 2, 表 3 に示す。

表 2: パラメータ設定のための MAP による評価

	data1	data2	data3	data4	Average
$k=20$	0.02676	0.02520	0.02229	0.02749	0.02544
$k=50$	0.03400	0.03239	0.02789	0.03396	0.03206
$k=100$	0.03717	0.03595	0.03118	0.03729	0.03540

表 3: パラメータ設定のための実行時間の計測

[sec]	data1	data2	data3	data4	Average
$k=20$	79372	86494	93753	85216	86209
$k=50$	121941	133157	142332	124994	130606
$k=100$	308476	332132	363782	331395	333946

表 2 の評価結果から、次元数ごとの Average の値の差は、 $k = 50$ と $k = 20$ は約 0.0066、 $k = 100$ と $k = 50$ は約 0.0033 となっている。これより、次元数を大きくするにつれて精度の上り幅が小さくなっていることが分かる。精度の上昇率が小さくなっている要因として、次元数を大きくするにつれてユーザーの好みを細かく表現できるようになるが、小さい次元数でもユーザーの好みの大枠は捉えられているため、次元数を大きくしても大幅な精度の向上にはならないからだと考えられる。一方、表 3 の評価結果では、次元数を大きくするにつれて、実行時間が大きく増加している。2 つの評価結果より、精度と実

アイテムベース手法、ユーザーベース手法ともに比較手法よりも優れた精度を示すことができた。ユーザーベース手法と WRMF のシステム上の差は順序性の考慮の有無である。そのため、順序性の考慮が精度の差に繋がったと考えられ、順序を考慮することの優位性を示すことができた。さらに、人気順の精度が低いことからユーザーの好みは人気アイテムに左右されず、それぞれのユーザーの好みのアイテムが存在することがわかる。そのため、他のユーザーの影響を考慮したユーザーベース手法よりもターゲットユーザーのみの好みを考慮したアイテムベース手法の精度がより高かったと考えられる。

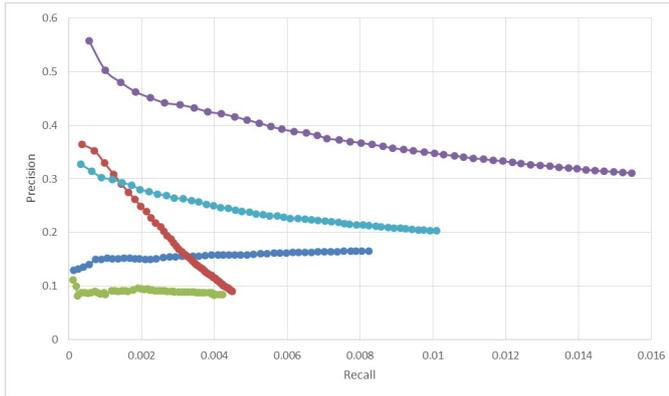
4.4 PR 曲線による評価

次に、 $recItems = 1, \dots, 50$ のそれぞれの推薦数についての考察を行うため、PR 曲線による評価を行う。実験結果を図 3 に示す。

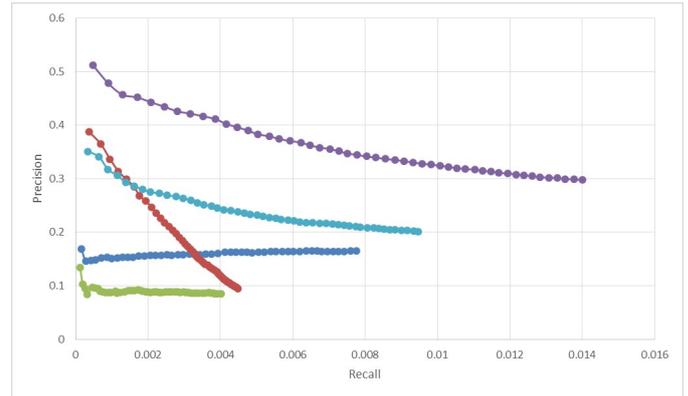
MAP と同様に、アイテムベース手法が最も優れた精度を示した。ユーザーベース手法は MAP の結果と異なり、推薦数が少ない場合には単純マルコフ過程よりも精度が下回った。単純マルコフ過程はユーザーベース手法よりも推薦数が少ない場合は優れていたが、推薦数を増やすにつれて精度が大幅に下がり、 $recItems = 10$ 以上ではどのデータに対しても精度が逆転し、ユーザーベース手法のほうがより優れている。これは、単純マルコフ過程がアイテムの遷移をアイテム ID で見ているため、遷移情報がスパースになり、ユーザーへの推薦ができなくなるためであると考えられる。一方ユーザーベース手法ではアイテムの遷移を連続値のベクトルで扱っているため、スパースになることがなく、ユーザーへの推薦が行えるため、精度の減少が少なくなっていると考えられる。

5. おわりに

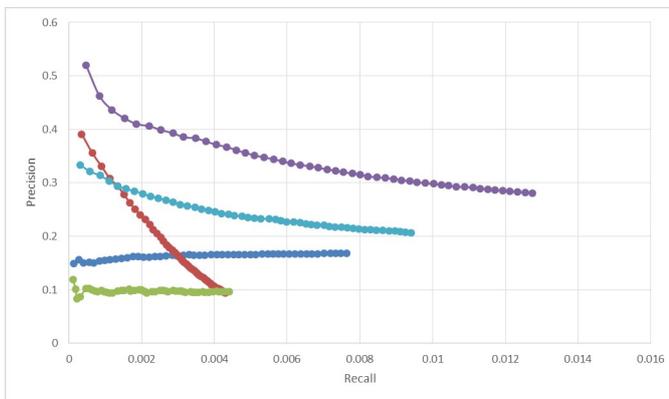
本稿では、ユーザーの好みの変化をユーザーの購買アイテムの順序性を見ることで最適な推薦を行う手法を提案した。ユーザーの好みの変化を考慮するため、カルマンフィルターを用い



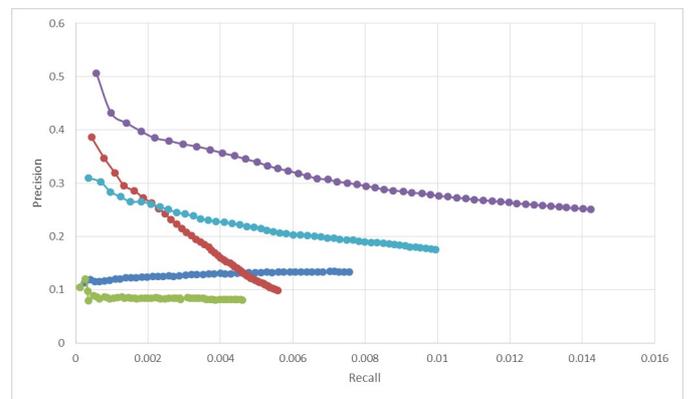
(a) data1



(b) data2



(c) data3



(d) data4

図 3: 比較手法との PR 曲線による評価 青:WRMF, 赤:単純マルコフ過程, 緑:人気順, 水色:ユーザーベース手法, 紫:アイテムベース手法

たことにより、ユーザーの全ての購買アイテムの順序性を考慮した推薦を可能にした。

実験では MAP、PR 曲線の 2 つの評価指標を用いて実験を行った。いずれの評価指標でも従来手法よりも優れた精度を示すことができた。さらに、他のユーザーの影響を考慮した推薦を行うユーザーベース手法よりもターゲットユーザーのみの好みの変化を考慮するアイテムベース手法のほうがより精度が高いことが確認できた。

本研究では、ユーザーの好みの変化は音楽の試聴ごとにかかるものであると仮定してシステムの構築を行った。しかしこの場合、友人と一緒に聞いた曲などユーザーの好みに影響しないアイテムも同様に学習されてしまう。今後の課題として、ユーザーが音楽を集中的に聞いている期間のアイテム群を 1 つのベクトルとみなしてユーザーの好みの変化を考慮する手法を考えている。これにより、ユーザーの好みをマクロに捕らえることでノイズの影響を減らし、さらなる精度の向上を狙いたいと考えている。

参考文献

- [奥 2009] 奥健太, 中島伸介, 宮崎純, 上村俊亮, 加藤博一: ユーザーコンテキストの時系列性を考慮した状況依存型情報推薦方式の有効性評価, DEIM Forum 2009.
- [Zhang 2015] Yongfeng Zhang, Min Zhang, Yi Zhang, Guokun Lai, Yiqun Liu, Honghui Zhang and Shaoping Ma: Daily-Aware Personalized Recommendation based on Feature-Level Time Series Analysis, WWW 2015.
- [Hu 2008] Y Hu, Y Koren and C Volinsky: Collaborative filtering for implicit feedback datasets, ICDM 2008.