

エージェントベースシミュレーションによる 確率潜在空間モデルを用いた推薦システムの評価に関する研究

情報数理応用研究

5211C004-7 井沢祐介
指導教員 後藤正幸

A Study on Evaluation of Model-based Collaborative Filtering Using Agent-based Simulation

IZAWA Yusuke

1 はじめに

近年、EC サイトでのアイテム数の増加やユーザ嗜好の多様化に伴い、各ユーザに適切なアイテム推薦を行う推薦システムの重要性が高まっている [1]。その中でも潜在クラスを仮定した Flexible Mixture Model [2](以下 FMM) が、未評価アイテムの評価値予測で高性能とされている。

一般的な推薦システムに関する研究では、モデルの性能はベンチマークデータを用いて評価されていることが多く、その統計的な特徴に左右される。さらに、多くのモデルはパラメータや閾値などの設定が推薦の前に必要であり、その最適値も評価に用いるデータの統計的特徴に依存する。このため、様々な状況下でのモデルの有効性や性能を明らかにするためには、多様なデータセットが必要になる。また、性能評価には一部欠損させたデータの値を予測する方式が採られているが、これは推薦がなされた下でのユーザ行動を表したものではない。実際の EC サイトの多くはデータが希薄な上に新規ユーザや新規アイテムが常時追加されていくため、推薦システムの立ち上がり時の性能評価が重要である。

これらの問題に対し、エージェントベースシミュレーション (以下 ABS) [3] により推薦システムを性能評価した研究が存在する [4] - [6]。ABS は自律的に意思決定を行うエージェントと、エージェントが行動する環境をモデル化しシステムの挙動を分析する手法である。ABS の適用により、想定する任意の市場環境において任意の推薦システムの性能を評価することができる。しかし従来行われている ABS を用いた推薦システムの研究では、単純な市場環境の下で相関係数法 [1] など基本的なメモリーベースの手法に対する分析に留まっている。より有効とされる FMM については、ABS による評価や分析が未だ行われていない。さらに、FMM はモデル構築に時間を要するため、データの更新に対し頻繁にモデルの再構築を行うことは現実的でなく、時間経過に従う再学習のタイミングの決定には ABS 等の動的な分析手法が有効である。

本研究では、以上の問題を想定した市場環境を ABS で構築し、FMM の特性について評価を行う。具体的にはデータ不足時からの性能上昇、潜在クラス数の意思決定基準、適切な再学習のタイミングの三点を明らかにする。

2 前提

2.1 推薦システム

推薦システムとは、ユーザのアイテムに対する購買行動や評価行動からユーザの嗜好を予測し、適切なアイテムを推薦する仕組みのことである。推薦システムにおける主要な手法として、嗜好の類似した他のユーザ情報から推薦すべきアイテムを推定する協調フィルタリングがある。

協調フィルタリングはデータから直接計算して推薦を行うメモリーベース協調フィルタリング [1](以下メモリーベース CF) と、データから統計モデルを作成して推薦を行うモデルベース協調フィルタリング [2](以下モデルベース CF) に分類される。本研究で用いる FMM はモデルベース CF に分類される。

推薦システムの研究におけるシミュレーション実験は、主に Movielens [1] 等のベンチマークデータデータを用いて行われることが多い。これらの多くは、データセットの一部を欠損させ、残りの部分で欠損部の値を予測する実験を行っている。しかしながら、この実験方法には三つの主要な問題が存在する [4], [5]。一点目は、異なる市場環境を表す多様なベンチマークデータを用意することが困難なことである。実験結果はユーザ嗜好など、データセットの持つ統計的かつ観測不可な特徴に依存する場合が多い。二点目は、上記の実験方法は、ある程度のデータ数を持つ、一時点のデータセットのみで性能評価を行っている点である。最後に、実際に推薦を行った結果に対するユーザの反応を評価できていないことである。実問題ではユーザの購買・評価行動からのデータの更新と、更新したデータでの推薦システムの再実行が繰り返されるため、これら考慮した動的な性能評価が望まれる。

2.2 Flexible Mixture Model

FMM とは [2]、 S_i らによって提案された確率潜在空間モデルであり、未評価アイテムの評価値推定を目的としている。いま、 I 個のアイテムからなるアイテム集合を $\mathcal{X} = \{x_i : 1 \leq i \leq I\}$ 、 J 人のユーザからなるユーザ集合を $\mathcal{Y} = \{y_j : 1 \leq j \leq J\}$ とし、評価値 r は R 段階 ($1 \leq r \leq R$) の離散値とする。ここで (x_i, y_j, r) はユーザ y_j がアイテム x_i に対し、評価値 r を付けたデータを表し、FMM ではこの 3 次元の情報のみを扱う。また、アイテムと評価値の発生源として潜在クラス (アイテムクラス) を仮定し、その集合を $\mathcal{Z} = \{z_k : 1 \leq k \leq K\}$ とする。一方、ユーザと評価値の発生源にも潜在クラス (ユーザクラス) を仮定し、その集合を $\mathcal{W} = \{w_l : 1 \leq l \leq L\}$ とする。このとき FMM の確率モデルは式 (1) で表現される。

$$P(x_i, y_j, r) = \sum_{k,l} P(z_k)P(w_l)P(x_i|z_k)P(y_j|w_l)P(r|z_k, w_l) \quad (1)$$

このモデルは、ユーザとアイテムに対して潜在クラス z_k, w_l を仮定し、同じような嗜好を持つユーザクラスと似たアイテムクラスにより評価値 r が決定されるというモデルである。このモデルは、ユーザとアイテムが各潜在クラスに所属する確率を規定していると捉えることもできる。式 (1) の $P(z_k), P(w_l), P(x_i|z_k), P(y_j|w_l), P(r|z_k, w_l)$ は

それぞれ多項分布に従うものとし、EM アルゴリズムで対数尤度を最大にするパラメータを推定する。得られたパラメータより、ユーザ y_j 、未評価のアイテム x_i 、評価値 r の同時確率である推定量 $\hat{P}(x_i, y_j, r)$ を式 (1) から求める。ユーザ y_j によるアイテム x_i に対する予測評価値を $\hat{r}(x_i, y_j)$ とすると、以下の式により求められる。

$$\hat{r}(x_i, y_j) = \sum_r r \frac{\hat{P}(x_i, y_j, r)}{\sum_r \hat{P}(x_i, y_j, r)} \quad (2)$$

全ての未評価アイテムに対して予測を行い、各ユーザに対し予測評価値の高い順に N 件の推薦を行う。

2.3 エージェントベースシミュレーション

ABS [3] は社会的なふるまいの調査に用いられる動的な分析手法である。ABS では、主にエージェント、エージェントがおかれた環境、エージェント同士の関係の三つの要素が重要である。エージェントとは異質性を持つ自律的な意思決定主体であり、この各々のエージェントの自律的な意思決定によってもたらされるシステム全体の挙動をシミュレーションにより再現する。各エージェントはある環境において、自身の行動基準に従い行動する。その際にエージェント同士の関係を仮定した場合、そのシステムはマルチエージェントシステムと呼ばれる。ABS を用いることで、設定した環境においてシステム全体の挙動とエージェントの挙動を考察することができる。

3 関連研究

3.1 ABS を用いた推薦システムに関する研究

前述の通り、推薦システムの研究で行われるベンチマークデータを用いた評価実験では、推薦アイテムに対するユーザの反応が考慮されていない。そのため、ABS を用いて推薦システムの評価を行った研究が既に存在する [4] - [6]。推薦システム評価のための ABS では、まず評価行動を行うエージェント (ユーザ)、アイテムと任意の推薦システムを設定する。その後、推薦システムが蓄積した評価データからエージェントに推薦を行うステップと、エージェントが推薦結果に対し評価を行うというステップを T 期繰り返し、その挙動を分析する。

ABS を用いた推薦システムには、推薦に用いる推薦システムと、エージェントが推薦アイテムを評価する行動を表現するモデル (ユーザ評価モデル) の決定が必要である。以下、これらの視点から既存研究の概要を述べる。

1) 推薦システム

ほとんどの既存研究はメモリベース CF が用いられている。Saga ら [4] はユーザ同士の類似度計算に相関係数を用いる相関係数法 [1] を対象としている。山下ら [5] は相関係数法と、同じユーザに買われやすいアイテム同士を算出するアイテムベース協調フィルタリングを結合したモデルを評価している。一方、梅田ら [6] はコサイン尺度でユーザ同士の類似度を計算している。これらは推薦システムに用いられている手法の中でも基本的なものであり、近年より有用であるとして注目されているモデルベース CF については、ABS の適用がなされていない。

2) ユーザ評価モデル

既存研究では、各エージェント (ユーザ) は嗜好ベクトルと呼ばれる商品の好みを表わすパラメータを、各アイテムは機能や品質特性が定量化された特徴ベクトルを持つ

ことを仮定している。エージェント y_j のアイテム x_i に対する評価値は、エージェント y_j の嗜好ベクトルとアイテム x_i の特徴ベクトルの類似度を変数とする関数から算出される。この関数を効用と定義する。嗜好ベクトルと特徴ベクトルの各要素は $\{0, 1\}$ の二値で構築されているため、既存研究では同じジャンルのアイテムに対する興味の強さの違いなど、実際の各ユーザや各アイテムが持っていると考えられる異質性は表現されていない。

3.2 本研究のアプローチ

上記の問題に対して、本研究ではモデルベース CF の中でも高性能とされる FMM を対象とし、先行研究に比べより現実的に則したユーザ評価モデルを設定する。また FMM を実際に運用した場合に生じる問題を想定し、それらに対する FMM の特性を評価する。

FMM は高性能な予測モデルとされているが、推薦システム全般の重要課題である、ユーザ数・アイテム数に対してデータ数が非常に少ない場合に性能が低下する希薄問題 [7] の影響を免れない。また、FMM 等の潜在クラスを用いたモデルでは、最適な潜在クラス数は探索的に決定されているため、市場環境を加味した潜在クラス数の決定基準はモデルを実問題に適用する際に重要である。さらに FMM はモデル構築に時間を要するため、実際の市場で想定されるアイテム数が増加していく環境の場合に、再学習をいつ行えばよいかという問題がある。以上の問題は ABS で人工的に市場環境を作成し、動的に分析を行うことで特性を評価することが可能である。その他の諸問題 (プライバシー保護、サクラ攻撃等) については個別に応用研究がなされているため、本研究ではまず以上の三つの主要な問題を想定した実験を行う。

4 FMM による ABS

4.1 シミュレーション概要

FMM を用いた推薦システムによる ABS の概要を、Saga ら [4] の形式を元に図 1 に示す。この図において、シミュレーターとは FMM を用いた推薦システムによる ABS であり、コンダクターとはシミュレーターの実行者を指す。なお、Saga ら [4] と山下ら [5] の研究同様、エージェントは推薦アイテムを必ず評価すると仮定する。また、本研究はエージェント同士の相互作用は考慮しない。

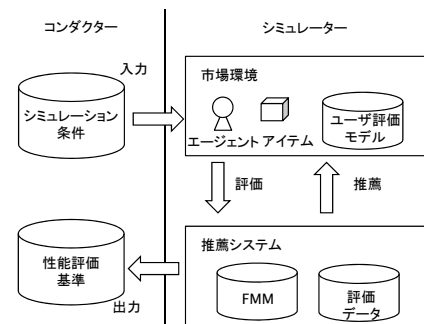


図 1:FMM を用いた ABS

以下の 6 ステップでシミュレーションは行われる。

Step1)(モデリングステップ) :次節で述べるようにユーザ評価モデルを設定し、各エージェントの推薦アイテムに対する評価値が決定されるようにする。モデリングの際には、ユーザの嗜好などを含むパラメータの真の値を仮定する。

Step2)(入力ステップ) :シミュレーターにエージェント数やアイテム数といったシミュレーション条件を入力する。期を $t = 1$ に設定する。

Step3)(推薦ステップ) :現在の評価データを入力として、推薦システムが式 (2) に基づきユーザの嗜好を予測し推薦を行う。初期にデータが蓄積されていない場合は、ランダム推薦を行う。

Step4)(評価ステップ) :真のパラメータから、推薦されたアイテムに対する各エージェントの評価値を計算する。

Step5)(出力ステップ) :推薦と評価の結果から、推薦システムの性能を評価する。

Step6)(更新ステップ) :次期の推薦のために、エージェントの評価がデータとして加えられる。 $t = t + 1$ とし、ステップ 3) へ戻る。設定した期数となった場合はシミュレーションを終了する。 □

4.2 ユーザ評価モデルの構成

前節より、ABS を用いた推薦システムにはユーザ評価モデルの構築が必要である。本研究ではより現実に則した市場環境で分析を行うため、データを発生させる真の確率モデルには FMM を仮定する。FMM はユーザとアイテムにそれぞれ潜在クラスを仮定しており、エージェントが複数の嗜好を持ち、アイテムが複数の特徴を持つ状況を表現するのに適したモデルである。さらにこれらの値は連続値となるので、全く同じ嗜好を持つユーザや特徴を持つアイテムが存在する状況が起りにくく、各エージェントと各アイテムの異質性を表現することができる。

真のアイテムクラス集合を $Z^* = \{z_k^* : 1 \leq k \leq K^*\}$ 、真のユーザクラス集合を $W^* = \{w_l^* : 1 \leq l \leq L^*\}$ とする。エージェント x_j のアイテム y_i に対する評価値の真の確率 $P^*(x_i, y_j, r)$ は式 (3) で表現される。

$$P^*(x_i, y_j, r) = \sum_{k,l} P^*(z_k^*)P^*(w_l^*)P^*(x_i|z_k^*)P^*(y_j|w_l^*)P^*(r|z_k^*, w_l^*) \quad (3)$$

ただし、 $P^*(\cdot)$ は全て真の確率を表す。式 (3) より、エージェント x_j がアイテム y_i を推薦された時の効用 $u(x_i, y_j)$ は式 (4) で表現される。

$$u(x_i, y_j) = \sum_r r \cdot \frac{P^*(x_i, y_j, r)}{\sum_r P^*(x_i, y_j, r)} \quad (4)$$

この効用はエージェントはユーザの真の満足度を意味し、高いほど評価値も高くなる。しかしながら評価値は R 段階の離散値であるため、以下の閾値 $s_0, s_1, \dots, s_r, \dots, s_R$ を用いて離散する。

$$s_r = \begin{cases} 1.0 & (r = 0) \\ 1.0 + \frac{r(R-1)}{R} & (r = 1, 2, \dots, R-1) \\ R & (r = R) \end{cases} \quad (5)$$

これらの閾値より、次式により効用 $u(x_i, y_j)$ をエージェント x_j のアイテム y_i に対する評価値 $r(x_i, y_j)$ に変換する。

$$r(x_i, y_j) = r \quad (s_{r-1} \leq u(x_i, y_j) < s_r) \quad (6)$$

4.3 パラメータの設定

ユーザ評価モデルにおいて、適切なパラメータの決定が必要となる。以下に本研究で用いたパラメータ設定法について述べる。例として、ユーザ y_j の各ユーザクラスへの所属確率 $P^*(y_j|w_1^*), P^*(y_j|w_2^*), \dots, P^*(y_j|w_l^*), \dots, P^*(y_j|w_{L^*}^*)$ の設定を考える。 a_l を $1, 2, \dots, A$ からランダムに抽出した l 番目の自然数とし、 α を w_l の指数となる非負定数とすると、真の所属確率は次式のように各乱数を L^* 個の乱数の総和で割ったもので設定される。

$$P^*(y_j|w_l^*) = \frac{a_l^\alpha}{\sum_{l=1}^{L^*} a_l^\alpha} \quad (7)$$

α の値を調整することで、 $P^*(y_j|w_1^*), P^*(y_j|w_2^*), \dots, P^*(y_j|w_{L^*}^*)$ の分布の偏り度合を変化させ、各エージェントがそれぞれ異なる嗜好を持つ状況を表現することができる。なお、 $\alpha = 0$ の場合は分布は一様分布となる。また、 $P^*(x_i|z_k^*), P^*(r|z_k^*, w_l^*)$ も同様の計算で設定した。今回はユーザ全体の嗜好とアイテム全体の特徴の偏りを考慮せず、 $P^*(z_k^*), P^*(w_l^*)$ に一様分布を仮定した。

4.4 シミュレーション条件

本研究のシミュレーションでは表 1 の値を用いた。各実験は 100 回繰り返され、結果の平均を算出している。

表 1:シミュレーション条件

変数	意味	値
I, J	エージェント数/アイテム数	500
R	評価段階	5
T	期数	20
N	推薦アイテム数	5
K^*, L^*	真のクラス数	5
A	乱数の取る値の大きさ	32768
α	a_l の指数	10.0

また、性能評価基準には平均効用 [5] を用いる。 $\delta_{i,j}^{(t)}$ を t 期にアイテム x_i がエージェント y_j に推薦されれば 1、そうでなければ 0 をとる関数とすると、 t 期の平均効用 $\bar{u}^{(t)}(x_i, y_j)$ は次式の様になる。

$$\bar{u}^{(t)}(x_i, y_j) = \frac{\sum_i \sum_j \delta_{i,j}^{(t)} u(x_i, y_j)}{nN} \quad (8)$$

前述の通り、本研究ではデータ不足時からの性能上昇の評価、潜在クラス数の意思決定基準、適切な再学習のタイミングの三問題に対する FMM の特性を評価することを目的とし、表 1 よりシミュレーション条件をそれぞれ変え実験を行う。

5 実験結果と考察

5.1 実験 1 : データ不足時からの性能上昇

以下では希薄問題を想定し、FMM を用いた推薦システムの初期段階からの時間経過による性能変化を評価する。比較手法として、毎期にランダム推薦を行う手法(ランダム)と、協調フィルタリングの基礎手法である相関係数法 [1](相関係数)を用い、FMM 同様のユーザ評価モデルで推薦アイテムに対し効用から評価値を計算した。なお、FMM の潜在クラス数には $K = L = 5$ を用いている。

図 2 は縦軸を平均効用、横軸を期としたものである。この図より、FMM が初期段階において他手法より平均効用が高いことが分かる。これは FMM が事前分布を仮定しており、データのスパース性を補って予測を行っている




図 2:時間経過による性能の変化

ためと考えられる。またエージェントとアイテムの全組み合わせに対する、既に評価が行われたユーザとアイテムの組み合わせの割合を「評価データの密度」と定義すると、本研究のシミュレーションでは評価データの密度が每期 1% ずつ増加していく。一般的に用いられるベンチマークデータの密度は 4% から 5% であり [1], 実データでは密度がさらに低いことも考えられる。従ってデータ密度が 5% 以下となる大規模な EC サイトのデータにおいて、FMM による予測が特に有効になることが明らかとなった。

5.2 実験 2: 潜在クラス数の決定

本実験では、FMM で設定した潜在クラス数が真のクラス数と異なった場合の FMM の性能評価を行う。実際の市場環境において、潜在クラスが仮定できる場合であってもその真の数は観測不可であり、また真の潜在クラス数と同じ潜在クラス数で学習を行った場合が最も高性能となる保証もないためである。真の潜在クラス数には $K^* = L^* = 5$ を用いた。この条件で $t = 5$ 期 (データ密度 4%) における平均効用を、潜在クラス数を変化させ計測を行った。縦軸にアイテムクラス数 H , 横軸にユーザクラス数 K をとった結果が表 2 である。

表 2: 潜在クラス数を変化させた場合の性能変化
ユーザクラス数

	1	2	3	4	5	6	7	8	9	10
1	3.02	3.02	2.97	2.98	2.92	2.94	2.97	2.96	2.98	3.01
2	3.01	3.13	3.12	3.23	3.2	3.15	3.22	3.15	3.22	3.2
3	3.17	3.25	3.28	3.26	3.28	3.32	3.28	3.32	3.36	3.32
4	3.25	3.29	3.31	3.33	3.31	3.35	3.34	3.35	3.31	3.35
5	3.17	3.32	3.32	3.36	3.38	3.38	3.38	3.35	3.38	3.42
6	3.2	3.33	3.35	3.36	3.4	3.36	3.4	3.37	3.41	3.4
7	3.23	3.38	3.36	3.32	3.4	3.39	3.41	3.42	3.41	3.44
8	3.28	3.33	3.4	3.32	3.35	3.4	3.43	3.39	3.42	3.46
9	3.27	3.34	3.42	3.36	3.37	3.39	3.46	3.47	3.44	3.41
10	3.32	3.36	3.36	3.39	3.39	3.41	3.45	3.46	3.47	3.44

上位 10 件の傾向から、潜在クラス数が真のクラス数より大きい場合に性能が高くなるのが分かる。また、下位 10 件と上位 10 件の傾向から、アイテムクラス数の変化がより性能に影響しているのがわかる。一般的な統計モデルでは、データが少ない場合にはよりシンプルなモデルの方が当てはまりが良い場合が多いが、潜在クラスを持つ FMM では、真のモデルを包含するより複雑なモデルの方が性能が良いことは特筆すべきである。これらの結果から、FMM を用いてアイテム推薦を行う際には初期段階において、潜在クラス数を大きく設定することに対しては性能低下を恐れる必要がないことが示唆される。

5.3 実験 3: モデルの再学習

本実験では実際の市場で想定されるアイテム数が増加していく環境のもと、モデル再学習のタイミングの分析

を行う。今回は評価データの密度を一定にしたままアイテムが増加していく市場環境を設定した。具体的には $t = 6$ 期以降に每期 100 個ずつアイテムを増加させ、每期学習を行う手法 (每期学習), $t = 5$ 期まで学習を行い、 $t = 5$ 期以降は同じモデルで推薦を行う手法 (初期学習), $t = 5$ 期まで以降は 5 期ごとに学習を行う手法 (定期学習) を比較した。図 3 にその結果を示す。




図 3: アイテム数増加時の性能変化

図 3 より、初期学習の性能は時間経過に従い低下する。これは新規アイテムを認識できずに初期のアイテム群からのみ推薦を行っているためと考えられる。反対に、每期学習の性能がほぼ横ばいを示していることが分かる。これは FMM が効用の高いアイテム群を継続的に推薦できているためと考えられる。また、定期学習の性能は再学習ごとに上下するが、三度目の再学習までは減少傾向に、それ以降は上昇傾向にある。前者は評価データの存在しない新規アイテムが推薦対象に含まれたまま学習が行われないこと、後者はパラメータ推定に用いるユーザ当たりのデータ数が増加したことが原因と考えられる。従ってアイテムが増加する市場の場合、学習には計算コストが生じることから初期段階では頻繁に学習を行い、データ数の増加に従い学習頻度を下げていくことが望ましい。

6 結論と今後の課題

本研究ではモデルベース協調フィルタリングに分類される FMM を用いた推薦システムに着目し、その性能評価を行うために ABS を構築しシミュレーションを行った。今後の課題として、他の推薦システムにおける問題に対する FMM の特性を分析していくことが挙げられる。

参考文献

- [1] Resnick, P, Iacovou, N, Suchak, M, Berstrom, P, Riedl, J, "An Open Architecture for Collaborative Filtering of News," *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work*, pp.175-186, 1994.
- [2] Si, L. and Jin, R., "Flexible Mixture Model for Collaborative Filtering," *Proceedings of the Twentieth International Conference on Machine Learning*, ICML 2003.
- [3] Gilbert, N. "Agent-Based Models," *Sage Publications*, 2007.
- [4] Saga, R, Okamoto, K, Tsuji, H, Matsumoto, K, "Proposal of a recommender system simulator based on a small-world model," *Artificial Life and Robotics* 16(3), pp.426-429.
- [5] 山下晃弘, 川村秀憲, 飯塚博幸, 大内東, "推薦と格付けの相互作用に基づく推薦アルゴリズムの性能評価," 情報処理学会論文誌. 数理モデル化と応用, Vol.2, No.2, pp. 47-57, 2009.
- [6] 梅田卓志, 小山友介, 市川学, 出口弘, "エージェントベースシミュレーションによる市場環境を考慮した協調フィルタリング手法の評価," 経営情報学会誌, Vol. 20, No.2, pp. 67-81, 2011.
- [7] 平山巧馬, 小柳滋, "協調フィルタリングにおける相関係数法の前測性能向上," 電子情報通信学会論文誌, Vol.J90-D, No.2, pp.223-232, 2007.