

Negative Feedback を考慮した推薦システムにおける公平性に関する研究

加茂 勇樹[†] 杉山 一成^{††} 吉川 正俊^{††}

[†] 京都大学 工学部 情報学科 〒 606-8501 京都市左京区吉田本町

^{††} 京都大学 情報学研究科 〒 606-8501 京都市左京区吉田本町

E-mail: [†]kamo.yuki.86x@st.kyoto-u.ac.jp, ^{††}{kaz.sugiyama,yoshikawa}@i.kyoto-u.ac.jp

あらまし 近年、推薦システムにおける公平性に関する研究が盛んに行われている。これは人気商品ばかりを推薦するのではなく、ロングテールグループとも呼ばれる人気のあまりない商品も推薦されるべきである、という考え方に基づいている。しかし、そのそれらの研究の多くは、positive feedback のみに着目した研究であり、negative feedback に着目した研究は少ない。そこで、本研究では、negative feedback を考慮した推薦システムの公平性に関する研究を行う。

キーワード 推薦システム, 公平性, negative feedback, 協調フィルタリング

1 はじめに

近年、推薦システムは、人々のあらゆる意思決定をサポートしている。例えば、オンラインショッピングサイトで商品の購入を検討する際、そのショッピングサイトには数多くの商品が存在するため、それらの一つずつ調べて、自分の好みに合う商品を見つけるには、かなりの時間がかかってしまう。このような時に、ユーザにおすすめの商品を推薦システムが提案することで、ユーザが購入する商品を決定するための負担を大幅に軽減することができる。オンラインショッピングサイトでの商品の提案以外にも、推薦システムは、広告やオンラインの就職情報の提案などにも用いられており [3]、今や人々の意思決定を大きく左右する重要なシステムである。

しかし、最近、推薦システムにおける公平性に懸念が示されており、それについて、盛んに研究されている。[8] [3] 推薦システムの公平性は、次の 2 種類に分類することができる。

- (1) 「ユーザに注目した公平性」
- (2) 「アイテムに注目した公平性」

(1) の「ユーザに注目した公平性」とは、性別や人種といったセンシティブな属性によって、意思決定プロセスが行われないようにするものである。これは近年、分析されたデータセットが大きくなるにつれて、市民団体や政府などから推薦システムの透明性や公平性が失われてしまうとして懸念されている [8]。

一方、(2) の「アイテムに注目した公平性」とは、アイテムの属性に着目した推薦システムにおける公平性のことである。推薦システムの多くは、推薦の精度だけを高めようとする、人気のある商品ばかりを推薦してしまう。これによりマタイ効果 [2] が生じてしまう。このマタイ効果とは、Wikipedia で以下のように説明されている。

「マタイ効果 (マタイこうか, 英語: Matthew effect) またはマタイ原理 (マタイげんり, 英語: Matthew principle) とは、条件に恵まれた研究者は優れた業績を挙げることでさらに条件に恵まれるという現象のことであり、それは科学界以外の

様々な分野でも見ることができる。「金持ちはより金持ちに、貧乏人はより貧乏に」と要約できる [1][2]。この概念は名声や地位の問題にも当てはまるが、上述した要約のとおり、経済資本の累積的優位性にも当てはめることができる。」

つまり、推薦システムにおけるマタイ効果というのは、人気のある商品はより推薦され、さらに人気が出てしまい、人気のない商品というのはあまり推薦されず、より人気がなくなってしまうということである。このことによって、人気のない商品を発見する機会が少なくなってしまう、少数のブランドや人気商品に市場が支配されてしまう可能性もある [7]。人気のない商品というのは、新商品などの、まだ評価のあまりつけられていない商品なども含まれる。つまり推薦システムにおいて、公平性というものを考慮しないと、新商品などが推薦される確率が低くなってしまい、市場で新たな商品が売られにくくなってしまふ。結果として、市場に商品の流動性が失われてしまう可能性がある。そこで本研究では、アイテムに注目した公平性に関する研究を行う。

推薦システムにおける研究では、positive feedback と negative feedback というものが考えられる。あるアイテムについて、ユーザからの positive feedback の例としては、以下のようものが挙げられる。

- 「ユーザがそのアイテムをクリックした」
- 「ユーザがそのアイテムを実際に購入した」
- 「ユーザがそのアイテムに対して、高い評価をつけた。」

つまり、ユーザがそのアイテムに対して、好意的に考えているとみなすことのできる行動のことである。

また、あるアイテムについて、ユーザからの negative feedback の例としては、以下のようなものが挙げられる。

- 「ユーザがそのアイテムをスキップした」 [7]
- 「ユーザがそのアイテムのページから、以前見ていたページに戻る」
- 「ユーザがそのアイテムに低い評価をつける」

つまり、ユーザがそのアイテムに対して、好意的に考えていないとみなされる行動のことである。

ここで、従来の推薦システムにおける公平性に関する研究では、「positive feedback のみに着目した研究」が多く、「positive feedback だけでなく、negative feedback にも着目した研究」は少ない。そこで本研究では、negative feedback を考慮した推薦システムにおける公平性について取り扱う。具体的には、協調フィルタリングを用いて推薦システムを構成する。アイテムの評価値計算を行う際に、positive feedback だけを用いたモデルと、positive feedback と negative feedback の両方を用いたモデルを用意し、それぞれを比較する。

今回実験に用いるデータセットは MovieLens Latest Dataset で、評価値に閾値を設けて、その閾値を超えるものを positive feedback、閾値を下回るものを negative feedback と見なす。

また、アイテムを人気グループとロングテールグループに分ける。ロングテールグループというのは、新商品やあまり売られていない商品を含む、人気グループに属さないアイテムのことである。公平性を考慮するため、あるユーザへのあるアイテムの評価値をつける際に、それが人気グループのアイテムである場合は、ペナルティを設け、それがロングテールグループのアイテムである場合は、ペナルティを設けない。これにより、人気商品が推薦されにくくなる。このようにした時、positive feedback のみを考慮したモデルと、negative feedback も考慮したモデルで、推薦精度、公平性の精度にどの程度の差ができるかを示す。また人気グループに対するペナルティはどの程度にするべきなのかも実験し、考察する。以上をまとめると、本研究で取り組む内容は、次のとおりである。

- positive feedback のみを考慮した推薦システムと negative feedback も考慮した推薦システムの推薦の精度と公平性の精度にどの程度の差が見られるか。
- 人気グループを推薦する際の、アイテムの評価値に対するペナルティはどの程度にするべきなのか。

2 関連研究

2.1 推薦システムで用いられる協調フィルタリング

推薦システムの研究では、協調フィルタリングを用いた方法が多く用いられている。協調フィルタリングは、インターネットの Albert Analytical Technology で以下のように説明されている。

「協調フィルタリングとは、ある対象者が商品をチェックまたは購入したデータと、対象者以外がチェックまたは購入したデータの両方を用い、その購入パターンから人同士の類似性、または商品間の共起性をアソシエーション分析（相関分析）で解析し、対象者個人の行動履歴を関連づけることでパーソナライズされた商品を提示することができる手法です。」[1]

つまり、興味や関心の類似した人は、類似した商品を購入すると言った仮定を用いてユーザの興味や関心に適合するアイテムを推薦する手法のことである。協調フィルタリングにはユーザベースの協調フィルタリング [5] とアイテムベースの協調フィルタリング [6] がある。ユーザベースの協調フィルタリングでは、対象となるユーザと類似しているユーザを、過去のユーザ

によるアイテムの評価から推定する。対象となるユーザと同じ嗜好を持っていると考えられるユーザが好むアイテムは、対象となるユーザも好むという考え方によって、アイテムをユーザに推薦する。

ユーザベースの協調フィルタリングには以下の二つの問題点がある。

- アルゴリズムのスケーラビリティが小さくなってしまう。ユーザベースの協調フィルタリングは、数万人の潜在的な類似したユーザをリアルタイムに検索することができたが、数千万人の潜在的なユーザをリアルタイムに検索することは難しい
- ユーザへの推薦精度があまり高くないこと

これらの課題への解決策として、Sarwar ら [6] は、アイテムベースの協調フィルタリングの手法を提案した。彼らは、スケーラビリティの向上と推薦精度の向上という、相反すると考えられる二つの問題点を同時に扱った。アイテムベースの協調フィルタリングでは、ユーザが評価したアイテムの集合を調べ、それらがどれほどターゲットとなるアイテムに類似しているかを計算する。そして、最も類似していると判断されるアイテムをいくつか選択するという手法である。この研究では、アイテムベースの協調フィルタリングが、大規模なデータセットに対応し、同時に高精度なアイテムの推薦を行うことができることを示した。

しかし、Sarwar らの実験では、人気アイテムだけでなく、ロングテールグループのアイテムも推薦されるべきというアイテムに注目した推薦システムの公平性には着目されていない。つまり、人気アイテムがより推薦されてしまう、というマタイ効果を防ぐことについては、考慮されていない。

2.2 推薦システムにおける公平性

推薦システムの分析するデータセットが大きくなっていくにつれ、その公平性についての研究がますます盛んに行われている。[8] [3]. 推薦システムにおける公平性については、ユーザに着目した公平性とアイテムに着目した公平性がある。性別や人種などのセンシティブな属性に基づいて、推薦システムを構築すると、差別待遇の対象になってしまうため、それを防ぐため、ユーザに注目した公平性の研究が盛んになってきた。また、人気商品ばかりが推薦されてしまうマタイ効果が、推薦システムの複雑化に伴い、顕著に現れるようになってきたため、アイテムに着目した公平性の研究も多く行われるようになった。

Ge ら [3] は、強化学習を用いた公平性を考慮する推薦システムを提案した。彼らは、これまでは静的なアルゴリズムが多かった推薦の分野で、長期的な公平性を担保すべく、動的な公平性アルゴリズムを提案した。ここで静的とは、推薦の過程で、モデルが変化しないということで、動的とは、その過程で、モデルの変化があり得る、ということである。また、彼らはユーザに着目した公平性ではなく、アイテムに着目した公平性を担保しようとしている。具体的なアルゴリズムは、強化学習を用いているため、制約を満たした上で、報酬関数の値を最大化させることを目標としている。この研究では、報酬関数 $R(s^t, a^t, s^{t+1})$ を以下のように定義している。 a^t は推薦するア

アイテムで、 s^t はマルコフ決定過程における状態を表している。

$$R(s^t, a^t, s^{t+1}) = \sum_{l=1}^K 1(a_l^t \text{ gets positive feedback})$$

つまり、推薦するアイテムの中でユーザーが positive feedback を示したものはいくつあるかを考えている。positive feedback というのはユーザーがアイテムに対して、好意的に考えているとみなされる行動のことである。例えば、ユーザーによるアイテムのクリックや、アイテムの視聴や購入などが挙げられる。また、コスト関数 $C(s^t, a^t, s^{t+1})$ を以下のように定義している。

$$C(s^t, a^t, s^{t+1}) = \sum_{l=1}^K 1(a_l^t \text{ is in sensitive group})$$

つまり、推薦するアイテムの中で、sensitive group に属するものがいくつあるかを示している。sensitive group というのは人気グループのことを示しており、このコスト関数の値を制限することで、人気グループのアイテムの推薦を抑制している。彼らは推薦システムのインタラクションをマルコフ決定過程 [4] によりモデル化した。さらに、人気アイテムの視認性を動的に制約した制約付きマルコフ決定過程に変換した。その後、制約付きポリシー最適化を用いて、異なる公平性の制約のもとで、最適なポリシーを学習した。Ge らは、実験の結果、提案手法が、推薦精度、短期的公平性、長期的公平性の観点から良い性能を発揮することを示した。

しかし、Ge らの手法では、ユーザーの positive feedback しか考慮しておらず、negative feedback は考慮されていない。

3 提案手法

2.1 節の推薦で用いられる協調フィルタリングの研究では、推薦の公平性について考慮されていない。2.2 節の推薦システムにおける公平性についての研究では、ユーザーの positive feedback について考慮されているが、negative feedback については考慮されていない。そこで、本研究においては、negative feedback を考慮した推薦システムにおける公平性についての手法を提案する。

3.1 Positive Feedback と Negative Feedback の定義

本研究では、positive feedback だけを考慮したモデルと、positive feedback と negative feedback の両方を考慮したモデルを考え、推薦の精度と公平性の精度がどのようになるかを実験し、考察する。したがって、positive feedback と negative feedback の定義を行なっておく必要がある。実験では MovieLens のデータセットを使用する。MovieLens のデータセットでは、ユーザーのアイテムに対する rating が 0.5-5.0 の間の数値を用いて記述されている。そのため、本研究ではある閾値を考え、その閾値以上の rating をユーザーがあるアイテムに対してしている時、ユーザーがそのアイテムに対して positive feedback を示していると考え、その閾値を下回った時、ユーザーがそのア

アイテムに対して negative feedback を示していると考ええる。

3.2 アイテムの人気グループとロングテールグループへの分類

まず、アイテムを人気グループとロングテールグループへ分類することを考える。本研究は、人気商品ばかりが推薦されるようになってしまうマタイ効果を軽減することを目標としている。そのため、人気グループのアイテムが、ロングテールグループのアイテムと比べて、推薦されにくくする必要がある。したがって、人気グループに属するアイテムの評価値をつける時、そのアイテムにペナルティを与える。人気グループとロングテールグループの分類では、アイテムに対して示された positive feedback の数を参照する。positive feedback の数が多いアイテムを人気グループとする。具体的には、アイテムに対してなされた positive feedback の数が、上位 10% のアイテムを人気グループに分類し、それ以外のアイテムをロングテールグループに分類する。ここでロングテールグループに属したアイテムが、より推薦されるようになるモデルを構築することが本研究の目的である。

3.3 ユーザ間の類似度計算

協調フィルタリングの手法を用いるにあたって、ユーザー間の類似度を計算する必要がある。つまり、ここで類似していると推定されたユーザーの評価値が、類似していないと推定されたユーザーの評価値と比べて、アイテムの評価値計算の際に、より重視されることとなる。あるユーザーとあるユーザーの類似度を計算する際、まずそれぞれのユーザーが評価をつけたアイテムの集合をそれぞれのユーザーに対して求める。そして、それらの共通集合をとることで、二人のユーザーが両方評価をつけたアイテムの集合を求める。これらのアイテムに対して、ユーザーの示した feedback が positive か negative かをチェックする。互いの feedback が同じであるアイテムの数が多いほど、類似度は高いと評価される。逆に、互いの feedback が異なるアイテムの数が多いほど、類似度は低いと評価される。具体的には、feedback が同じアイテムの数を A とし、feedback が異なるアイテムの数を B とすると、類似度 S は、次式のように定義される。

$$S = \frac{1}{1 + \sqrt{\frac{B}{A+B}}}$$

あるユーザーに対するアイテムの評価値をつける際、類似度の高いと判断されたユーザーの情報がより重要視されることになる。

3.4 アイテムの評価値計算

あるユーザーに対して、各アイテムの評価値を計算する。その際に評価値の高いアイテムをユーザーへ推薦することになる。評価値を計算する際に、ユーザー間の類似度も考慮する。また、本研究では、人気グループとロングテールグループのアイテムの推薦における視認性の公平性を担保しようとしている。そのため、人気グループに属しているアイテムに対して、ユーザーの評価値をつける際、そのアイテムの評価値にペナルティを設ける。また、ロングテールグループに属するアイテムに対して、その

アイテムの評価値をつける際は、ペナルティを設けない。このようにすることで、人気グループの評価値がやや低くなり、推薦されるアイテムにロングテールグループに属するアイテムが多くなると考えられる。さらにアイテムの評価値を計算する際に、positive feedback と negative feedback を考慮するモデルと positive feedback のみを考慮し、negative feedback は考慮しないモデルをそれぞれ考える。具体的には、あるユーザーに対して、あるアイテムの評価値を計算する際に、そのアイテムに評価をつけた他のユーザーが positive feedback を示しているのか、negative feedback を示しているのかを考慮する。positive feedback を示しているときには、そのアイテムに対する評価値を大きくする。negative feedback を示しているときには、それぞれのモデルにより評価値の与え方を変える。具体的には、以下のように negative feedback の評価値を与える。

- 「positive feedback」のみを考慮し、「negative feedback」は考慮しないモデル
 - アイテムに対する評価値に影響を与えない。
- 「positive feedback」と「negative feedback」の両方を考慮するモデル
 - アイテムに対する評価値を変化させる。

また、negative feedback を考慮するモデルにおいて、negative feedback がアイテムに対して示され、評価値を変化させる際、どのような変化をさせるかも比較し、実験する。

4 実験方法

4.1 データセット

本研究の実験では、MovieLens Latest Datasets をデータセットとして用いる。本データセットにおいて、movies.csv は映画の情報を持ったデータベースで、ratings.csv はユーザーが映画に対してどのような評価をしたかを格納したデータベースである。

movies.csv に格納されているデータは、以下の3つである。

(1) movieID

それぞれの映画に割り当てられた ID で、一つのデータに唯一の値が割り当てられる。つまり、データの中で同じ movieID を持ったデータは存在せず、1 から 193609 の数字で表されている。具体例は「1」、「45」、「242」などである。

(2) title

それぞれの映画に対応する映画のタイトルと公開された年が格納されている。具体例は「Toy Story (1995)」や「Stranger in the House (1997)」などである。

(3) genres

映画のジャンルが格納されたものである。このデータの中には、複数のデータで共通して持たれている値が存在する。また、複数のジャンルに入ると考えられる映画については、値が複数存在する。具体例は「Comedy—Drama—Romance」、「Action」などである。

また ratings.csv に格納されているデータは以下の4つである。

(1) userId

映画に対して評価をしたユーザーを、一意に識別するための ID である。1 から 610 までの数字を用いている。具体例は、「1」、「435」などである。

(2) movieId

ユーザーが評価をした映画を、一意に識別するための ID である。ここに格納されているデータの値は全て movies.csv の movieID にも存在するものである。これにより、ここで評価された映画がどのような映画であるかを識別することができる。

(3) rating

ある userId を持つユーザーが、ある movieId を持つ映画にどのような評価をつけたかを示すデータである。0.5 から 5.0 までの数字で表されており、0.5 刻みで評価がつけられている。この数値が大きいほど、ユーザーはその映画を高く評価していることを示す。具体例としては、「4.0」、「2.5」などである。

(4) timestamp

評価がいつ行われたものであるかを示したものである。このデータは 1970 年 1 月 1 日の協定世界時 (UTC) 午前 0 時から秒数を表している。つまり、大きな整数でデータが格納されている。具体例は、「964982703」、「847435311」などである。

本研究では、これらのデータが格納されている movies.csv と ratings.csv を用いて実験を行った。

4.2 データの整形

movies.csv と ratings.csv を実験に用いるが、以下の手順にしたがって、データの整形を行う。

(1) movies.csv と ratings.csv の両方に存在する movieId をキーとして、両方のデータを結合する。これにより、ユーザーが評価をした映画がどのような映画であるかが、一つのテーブルでわかるようになる。

(2) rating をバイナリにする。具体的には、rating が 4.0 以上のものを positive feedback を示していると考え、rating が 4.0 未満のものを negative feedback を示していると考え。そしてデータに新たな行「pos_neg」を追加する。positive feedback を示していると考えられるデータは pos_neg の値を 1.0、negative feedback を示していると考えられるデータは pos_neg の値を 0.0 とする。これによりユーザーが映画に対してした評価をバイナリで示すことができる。

(3) title と userId, pos_neg を用いて二次元の表を作成する。行に title を指定し、列に userId を指定する。表の中身に、それぞれの userId に対して、title の pos_neg の値を格納する。すなわち userId と title を指定すると、そのユーザーがその title を持つ映画に対して、positive feedback を示しているのか、negative feedback を示しているのかが一目でわかるようになる。またこのデータでは、全ての title と userId に対して値が存在しているわけではない。そのため、値が存在しないデータについては None が格納されている。

4.3 実験で用いる評価尺度

実験の評価尺度では、推薦の精度を測る指標と推薦における

公平性を測る指標を用いる。推薦の精度を測る指標としては、適合率、再現率、 F 値を利用する。また公平性を測る指標としては popularity Rate を使用する。それぞれについて簡単な説明を以下に示す。

- 適合率

推薦システムが提示したアイテムのうち、どれだけが適合文書であるかを示した割合のこと。適合率が大きい方が、推薦システムの精度が高いことを示す。

- 再現率

適合文書のうち、いくつのアイテムを推薦システムが提示したかの割合のこと。再現率が高い方が推薦システムの精度が高いと言える。

- F 値

適合率と再現率を両方考慮した指標。両者の調和平均をとることで表される。適合率を P 、再現率を R とすると、 F 値は次式によって定義される。 F 値が大きい方が、推薦システムの精度が高いと言える。

$$F = \frac{2PR}{P + R}$$

- Popularity Rate

推薦システムの公平性を表す指標である。推薦されたアイテムのうち、どれだけのアイテムが人気グループに属しているかの割合のこと。popularity Rate の値が小さい方が公平性が大きいと言える。

- Longtail Rate

推薦システムの公平性を表す指標である。推薦されたアイテムのうち、どれだけのアイテムがロングテールグループに属しているかを示す割合のこと。popularity Rate を P とすると、 $1 - P$ で表される。

4.4 変化させるパラメータ

この実験では、モデルを構築するパラメータを変化させ、それにより推薦システムの精度や推薦システムの公平性がどのように変化するかを考察する。具体的に変化させるパラメータを以下で説明する。

- penalty

本研究では、人気グループのアイテムばかりが推薦されてしまうマタイ効果を防ぐため、人気グループに属するアイテムの評価値についてペナルティを設けている。どの程度のペナルティを与えるかを設定するのが本パラメータである。値は「0.2, 0.5, 0.75, 1.0」の数値で変化させ、実験を行う。1.0 の penalty を持つモデルについては、人気グループとロングテールグループでアイテムの評価値に差が生まれにくい。そのため、1.0 のモデルでは人気グループの推薦される割合が大きくなることが予想される。また 1.0 以外の数値では、0.2 が最も人気グループに課せられるペナルティが大きく、0.75 が最もペナルティが小さくなる。したがって、0.2 の penalty を持つモデルが最も人気アイテムが推薦されないと推測できる。

- neg_score

アイテムに評価値をつける際に、negative feedback を考慮す

るかどうか、本研究において重要な点である。また、どの程度 negative feedback とするかを考慮する必要がある。neg_score は negative feedback を考慮するのか、また、考慮するならば、どの程度とするのか、を設定する変数である。値は、「0.0, -0.5, -1.0」の数値で変化させる。0.0 を持つモデルが、評価値をつける際に negative feedback を使用しないモデルである。neg_score に -0.5, -1.0 を持つモデルが、アイテムの評価値をつける際に negative feedback を使用するモデルである。また、neg_score に -0.5 を持つモデルよりも、neg_score に -1.0 を持つモデルの方が、negative feedback をより考慮していると考えられる。

5 実験結果・考察

3 章で提案した手法について、実験を行ない、考察する。本研究では、negative feedback を考慮するモデルを用いた推薦システムと、negative feedback を考慮しないモデルを用いた推薦システムの両方を比較する。また人気グループに対して、ペナルティを設けるモデルを用いた推薦システムとペナルティを設けない推薦システムの比較も行う。negative feedback を考慮するかしないか、人気グループへのペナルティを与えるか与えないかで、表 1 に示す実験 1 から実験 4 の 4 パターンの実験を行う。表 1 に今回実験を行うモデルのパターンを示す。結果は小数第 4 位を四捨五入して示す。

表 1 実験のパターン

実験のパターン	negative feedback	ペナルティ
実験 1	考慮しない	与えない
実験 2	考慮しない	与える
実験 3	考慮する	与えない
実験 4	考慮する	与える

5.1 実験 1

実験 1 では、アイテムの評価値計算を行う際に、neg_score が 0 で、人気グループに属するアイテムに対してのペナルティを設けないモデルを使った推薦システムを用いた。つまり negative feedback と推薦の公平性を考慮していないモデルである。表 2 にこのモデルを用いた推薦システムの精度を表す指標をまとめたものを示す。また表 3 にこの推薦システムの公平性を表す指標をまとめる。

表 2 実験 1 における推薦の精度

パラメータ		推薦の精度		
penalty	neg_score	適合率	再現率	F 値
1.0	0.0	0.717	0.141	0.236

表 3 実験 1 における公平性の精度

パラメータ		公平性の精度	
penalty	neg_score	popularity Rate	longtail Rate
1.0	0.0	0.828	0.172

人気グループに対して、ペナルティを設けていないため、popularity Rate の値がかなり大きくなっている。全体の 10% しかない人気グループが推薦されたアイテムの、おおよそ 72% を占めていることとなる。このモデルでは、推薦システムにおける公平性が担保されているとは言い難い。

5.2 実験 2

実験 2 では、アイテムの評価値計算を行う際に、neg_score が 0 で、人気グループに属するアイテムに対してのペナルティを設けるモデルを使った推薦システムを用いた。つまり negative feedback を考慮せず、推薦の公平性を考慮するモデルである。表 4 にこのモデルを用いた推薦システムの精度を表す指標をまとめたものを示す。また、表 5 にこの推薦システムの公平性を表す指標をまとめる。

表 4 実験 2 における推薦の精度

パラメータ		推薦の精度		
penalty	neg_score	適合率	再現率	F 値
0.75	0.0	0.684	0.136	0.227
0.5	0.0	0.646	0.126	0.212
0.2	0.0	0.607	0.120	0.201

表 5 実験 2 における公平性の精度

パラメータ		公平性の精度	
penalty	neg_score	popularity Rate	longtail Rate
0.75	0.0	0.649	0.351
0.5	0.0	0.479	0.521
0.2	0.0	0.316	0.684

penalty の値が小さくなればなるほど、人気グループに属するアイテムの評価値は小さくなり、人気グループに属するアイテムが推薦されにくくなる。そのため、penalty の値が小さくなると、それに伴って、popularity Rate の値が小さくなっている。つまり penalty の値が小さくなると、推薦の公平性が高まっていると言える。また、penalty の値が小さくなるにつれて、適合率も小さくなっている。これは、positive feedback を得られやすい人気グループを推薦しにくくなるためであると考えられる。popularity Rate が下がり、推薦の公平性が向上すると、適合率が下がり、推薦の精度が低下している。一般に推薦の精度と推薦の公平性にはトレードオフがあることが示されており、本実験においても、その結果が表れている。

5.3 実験 3

実験 3 では、アイテムの評価値計算を行う際に、neg_score が 0 でなく、人気グループに属するアイテムに対してのペナルティを設けないモデルを使った推薦システムを用いた。つまり negative feedback を考慮して、推薦の公平性を考慮しないモデルである。neg_score が -1.0 のモデルの方が、-0.5 のモデルと比べてより negative feedback の影響を受けているモデルである。表 6 に、このモデルを用いた推薦システムの精度を表す指標をまとめたものを示す。また、表 7 に、この推薦システム

表 6 実験 3 における推薦の精度

パラメータ		推薦の精度		
penalty	neg_score	適合率	再現率	F 値
1.0	-0.5	0.709	0.140	0.234
1.0	-1.0	0.727	0.126	0.237

表 7 実験 3 における公平性の精度

パラメータ		公平性の精度	
penalty	neg_score	popularity Rate	longtail Rate
1.0	-0.5	0.791	0.209
1.0	-1.0	0.773	0.227

の公平性を表す指標をまとめる。

推薦の精度に関しては、F 値に注目するとあまり差は見られなかったが、やや neg_score が -1.0 の場合に高い精度が得られた。また公平性の精度については実験 1 と比較すると、popularity Rate が総じて小さくなっており、公平性の精度は高まっていると言える。人気グループに対してペナルティを与えない場合、negative feedback を考慮した方が、公平性の精度が高まるということが確認できた。

5.4 実験 4

実験 4 では、アイテムの評価値計算を行う際に、neg_score が 0 でなく、人気グループに属するアイテムに対してのペナルティを設けるモデルを使った推薦システムを用いた。つまり negative feedback を考慮して、推薦の公平性を考慮するモデルである。表 8 にこのモデルを用いた推薦システムの精度を表す指標をまとめたものを示す。また、表 9 にこの推薦システムの公平性を表す指標をまとめる。

表 8 実験 4 における推薦の精度

パラメータ		推薦の精度		
penalty	neg_score	適合率	再現率	F 値
0.75	-0.5	0.700	0.138	0.231
0.5	-0.5	0.676	0.134	0.224
0.2	-0.5	0.665	0.131	0.219
0.75	-1.0	0.713	0.140	0.234
0.5	-1.0	0.698	0.137	0.229
0.2	-1.0	0.690	0.135	0.226

表 9 実験 4 における公平性の精度

パラメータ		公平性の精度	
penalty	neg_score	popularity Rate	longtail Rate
0.75	-0.5	0.707	0.293
0.5	-0.5	0.605	0.395
0.2	-0.5	0.512	0.488
0.75	-1.0	0.725	0.275
0.5	-1.0	0.680	0.320
0.2	-1.0	0.605	0.395

neg_score を固定して、penalty の値を小さくしていくと、やはり、適合率は低下することが確認できる。これは、positive

feedback の多い人気グループのアイテムが推薦されにくくなるためである。そのため popularity Rate も penalty の値を小さくしていくことで、小さくなることが確認できる。popularity Rate の値が小さい方が推薦の公平性の精度が高まっていると言えるので、penalty の値が小さくなると、公平性が高まっていると言える。

また、penalty の値を固定して、neg_score の値を小さくすると、適合率は低下することが確認できる。この結果から、negative feedback を重視した方が推薦の精度が向上することがわかる。しかし、neg_score の値を小さくすると、popularity Rate は大きくなっているため、negative feedback を考慮した方が、より推薦の公平性がより低下してしまうことがわかる。

これらの結果から negative feedback を考慮して、negative feedback を受けたアイテムの評価値を小さくすると、推薦の精度が向上し、公平性の精度が低下することがわかる。

5.5 実験結果のまとめ

本研究では、表 1 に示した 4 パターンのパラメータの変化により、実験を行った。neg_score を変化させることによって得られる評価値について、考察する。図 1 は neg_score の変化により適合率がどのように変化しているかを、penalty の値ごとに示したグラフである。penalty の値が 1, 0.5, 0.2 の各値について、適合率の変化を示している。

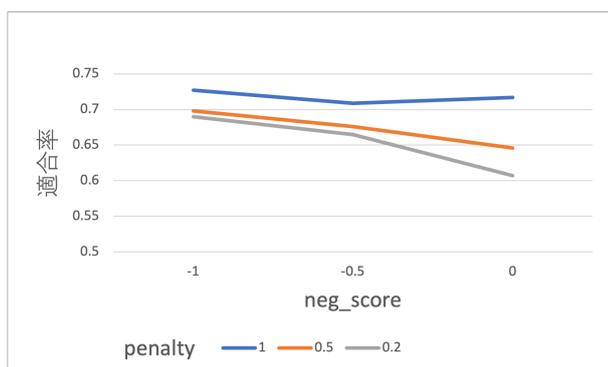


図 1 neg_score による適合率の変化

図 1 に示すように、neg_score が大きくなると、penalty が 1 である場合を除いて、適合率が右肩下がりに小さくなっている。また penalty が 1 の時は、neg_score による適合率の変化は小さい。すなわち、人気グループに対してペナルティを設ける場合は negative feedback を考慮すると推薦の精度が向上することがグラフからわかる。人気グループに対してペナルティを設けない場合は、negative feedback を考慮することによる影響は小さい。

また、図 2 は、neg_score を変化させることにより、longtail Rate がどのように変化しているかを、penalty の値ごとに示したグラフである。penalty の値が 1, 0.5, 0.2 の値について、longtail Rate の変化を示している。図 2 に示すように、neg_score が大きくなると、penalty が 1 である場合を除いて、longtail Rate の値が大きくなっている。すなわち、人気グループに対して、ペナルティを設ける場合は negative feedback を

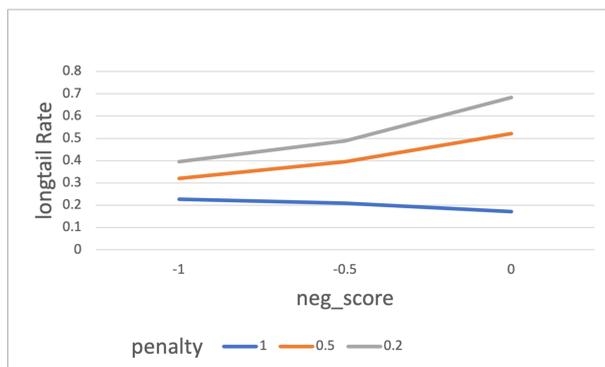


図 2 neg_score による longtail Rate の変化

考慮すると推薦の公平性が低下することがわかる。また人気グループに対して、ペナルティを設けない場合は、negative feedback を考慮することで推薦の公平性が、やや向上する。neg_score を小さくして、negative feedback を考慮したときに、longtail_rate が減少する理由としては、人気グループに対しては、negative feedback の数が少ないことが挙げられる。人気グループに属する映画は多くの positive feedback を受けている映画であるが、positive feedback を多く受ける映画は、negative feedback を受ける回数は少なくなると考えられる。negative feedback を受ける数が少ないとすると、アイテムの評価値計算の際に、negative feedback を受けていることによる評価値の減少の影響を受けにくくなる。したがって、neg_score を負の値にして、negative feedback で評価値を減少させようとしても推薦される人気グループのアイテムの数が少なくなると考えられる。また penalty の値が 1 の時は、そもそも人気グループの推薦される割合が高いため、neg_score の値を負の値にしても人気グループのアイテムがより推薦されるという現象が起こりにくかったと考えられる。

6 結論

本研究では、negative feedback を考慮した推薦システムと negative feedback を考慮しない推薦システムにおいて、推薦の精度と公平性の精度がどのように異なるかを実験し、考察した。また人気グループの商品が推薦されすぎないように、人気グループに対して、アイテムの評価値計算の際にペナルティを設けたが、そのペナルティをどのように与えるべきかについても実験し、考察した。negative feedback を考慮するかしないか、人気グループにどの程度のペナルティを設けるべきかで 4 パターンの実験を行った。

実験 1 では、negative feedback を考慮せずに、人気グループに対してもペナルティを与えないモデルを用いた推薦システムを用いて、実験を行った。推薦の精度は高かったが、人気グループに属するアイテムの推薦が多く、公平性の精度はあまり高くなかった。

実験 2 では、negative feedback を考慮せずに、人気グループに対してペナルティを与えるモデルを用いた推薦システムを用いて、実験を行った。推薦の精度は実験 1 と比べて高くなかつ

たが、人気グループに属するアイテムからの推薦の数が減り、公平性の精度が高くなった。

実験3では、negative feedback を考慮し、人気グループに対してペナルティを与えないモデルを用いた推薦システムを用いて、実験を行った。実験1と比べて、推薦の精度はやや向上し、popularity Rate が小さくなったため、公平性の精度も向上した。つまり人気グループに対して、ペナルティを設けない場合は、negative feedback を考慮した方が、推薦の公平性の精度は高まるということが確認できた。

実験4では、negative feedback を考慮し、人気グループに対してペナルティを与えるモデルを用いた推薦システムを用いて、実験を行った。総じて、人気グループに対するペナルティを大きくすると推薦の精度が下がり、推薦の公平性が向上することがわかった。また negative feedback をより重視するようにすると、推薦の精度が大きくなり、推薦の公平性の精度が低下することがわかった。

最後に negative feedback を考慮することによる影響を明確にするために、penalty の値を固定したときに、推薦の精度や公平性がどのように変化するかをグラフで示し、考察した。penalty の値によって、negative feedback の影響は異なるということが確認できた。しかし多くの場合で、negative feedback を考慮すると、推薦の精度は向上するが、推薦の公平性は低下するということがわかった。

今後の課題として、

- penalty の値が人気グループに対して一律だが、人気の度合いによって変化させることはできないか、
 - もう少し大きいデータセットを用いて実験を行っても実験の結果は変わらないのか、
 - negative feedback を考慮する方法には、他の方法はないのか、
 - ユーザ間の類似度計算をもう少し工夫することはできないか、
- などについて、取り組んでいきたいと考えている。

文 献

- [1] 協調フィルタリングとは. <https://urlzs.com/b1yzD>.
- [2] マタイ効果, 2021. <https://bit.ly/3s0Row6>.
- [3] Y. Ge, S. Liu, R. Gao, Y. Xian, Y. Li, X. Zhao, C. Pei, F. Sun, J. Ge, W. Ou, and Y. Zhang. Towards Long-term Fairness in Recommendation. In *Proc of the 14th ACM/International Conference on Web Search and Data Mining (WSDM 2021)*, page 445–453, 2021.
- [4] M. L. Puterman. *Markov decision processes: discrete stochastic dynamic programming*. John Wiley & Sons Inc., 1994.
- [5] P. Resnick, N. Iacovou, M. Suchak, and J. R. P. Bergstorm. GroupLens: An Open Architecture for Collaborative Filtering of Netnews. In *Proc. of the ACM 1994 Conference on Computer Supported Cooperative Work (CSCW 1994)*, pages 175–186, 1994.
- [6] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl. Item-Based Collaborative Filtering Recommendation Algorithms. In *Proc of the 10th International Conference on World Wide Web (WWW 2001)*, pages 285–295, 2001.
- [7] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl. Recommendations with Negative Feedback via Pairwise Deep Reinforcement Learning. In *Proc of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD 2018)*, pages 1040–1048, 2018.
- [8] M. B. Zafar, I. Valera, M. G. Rogriguez, and K. P. Gummadi. Fairness Constraints: Mechanisms for Fair Classification. In *Proc of the 20th International Conference on Artificial Intelligence and Statistics (AISTATS 2017)*, pages 962–970, 2017.