

分散表現を用いたユーザの書籍整列順序に基づく書籍推薦手法

宮本 達矢[†] 北山 大輔^{††}

[†] 工学院大学工学研究科 〒163-8677 東京都新宿区西新宿 1-24-2

^{††} 工学院大学情報学部 〒163-8677 東京都新宿区西新宿 1-24-2

E-mail: [†]tem18014@ns.kogakuin.ac.jp, ^{††}kitayama@cc.kogakuin.ac.jp

あらまし 近年、推薦システムは単純な精度による評価のみではなく、novelty や diversity, explainability, coverage に serendipity といったさまざまな観点からの評価が行われている。これは、単純な精度のみでは、ユーザに対し十二分な満足感を与えることができないと判明したためである。本論文では、serendipity と explainability を高めるために、ユーザの書籍整列順序に基づいた推薦システムを提案する。ユーザがいくつかの書籍を意図に基づいて順序に並べ替えるとき、ユーザごとに「コメディ要素が多くなる順」や「ミステリ要素の難しい順」などさまざまな整列意図が考えられる。そこで、我々はこの整列意図を予測し、整列意図に沿った書籍を推薦する。また、実際に整列意図に沿った書籍を推薦することができているか実験を行い確認する。

キーワード 分散表現, 書籍推薦, 回帰分析

1. はじめに

近年、推薦システムは単純な精度による評価のみではなく、novelty や diversity, explainability, coverage に serendipity といったさまざまな観点からの評価が行われている [1-3]。これは、単純な精度のみでは、ユーザに対し十二分な満足感を与えることができないと判明したためである。本論文では、ユーザの書籍整列順序に基づく serendipity と explainability を考慮した推薦システムを提案する。

上記の目的を達成するため、我々は書籍の並び順に注目した。ユーザがいくつかの異なる書籍を用いて並び順を考える場合、ユーザによってさまざまな順序が考えられる。このときの整列理由の例として、徐々にコメディ要素が増していく順や、ミステリの難しさ順といったような書籍ジャンルに注目した順番が考えられる。また、上記の例以外にも、書籍自体の読みやすさ順や雰囲気の良い順といった、単純には表し難いユーザの感覚に基づく順序という例も考えられる。

本推薦システムは、ユーザが入力した書籍の整列意図を理解し、ユーザの整列意図に沿った書籍を推薦する。推薦書籍はユーザの整列意図に沿っているため、ユーザはなぜその書籍が推薦されたのか、推薦理由を理解しやすいと考えられる。よって、本推薦システムが高い explainability を有していることを期待する。また、推薦システムがユーザが意図していなかった整列順序の法則を発見する可能性も存在する。この際、ユーザにとって意外な書籍が推薦されると予想される。以上のことから、serendipity の高い推薦を行うことも期待している。本論文の概要を図 1, 2 に示す。はじめに、レビューから分散表現を用いて書籍特徴ベクトルを作成する。次に、整列順序に沿って並べた特徴ベクトルの各要素に対し回帰分析を行うことで、ある位置の特徴ベクトルを予測する。最後に、各位置において最も類似度の高い書籍を推薦する。

本論文の構成は以下の通りである。2 節では関連研究につい

て述べる。3 節では分散表現を用いた整列順序に基づく書籍特徴の変化予測について述べる。4 節では提案手法による整列意図に沿った書籍推薦精度評価を行う。5 節では比較手法を用いた提案手法の有効性の検証を行う。6 節では本論文のまとめと今後の課題について述べる。

2. 関連研究

既に、数多くの書籍推薦手法が存在している。Givon ら [4] は、コールドスタート問題に対応した書籍推薦手法を提案した。発売されたばかりの書籍に対し、自動的にソーシャルタグを付与することで、コールドスタート問題に対応している。Minami ら [5] は、共感レビュアーに注目することで、ユーザの満足度を上げる手法を提案した。協調フィルタリングにおいて、ユーザと同様の観点を持つレビュアーの影響力を上げることで、ユーザの満足度向上を図っている。

複数のアイテムを一度に推薦する手法として、Liu ら [6] が提案したアイテムリストを推薦するためのモデルがあげられる。Liu らの注目したアイテムリストは、アイテム間に時系列を含めた順序関係は一切存在していない。しかし、我々の手法では、時系列順ではない順序によって並ぶ書籍整列に注目している。

serendipity に関する研究として、Oku ら [7] のフュージョンベース推薦システムがあげられる。ユーザが入力した 2 つのアイテムの特徴を組み合わせることで、2 つの特徴を併せ持つ新しいアイテムを推薦している。我々の提案手法では、ユーザの入力アイテム数を限定せず、また入力アイテムの位置関係によって異なるアイテムを推薦する。これにより、より多彩なアイテムが推薦されることを期待している。

explainability に関する研究として、タグクラウドを用いて推薦アイテムの説明を行なった Green ら [8] の研究があげられる。推薦元となるアーティストと推薦されたアーティストとの関係を、タグクラウドに表示される語の大きさによって表現している。我々の提案手法では、単語や文章によって直接ユーザ




図 1 レビューを用いた書籍特徴ベクトル作成の概念図




図 2 予測書籍特徴ベクトルを用いた書籍推薦の概念図

に推薦アイテムの説明を行うことはない。しかし、ユーザの考えた関連性に沿って推薦を行うことで、ユーザが入力アイテムとの関係性を理解できると考えている。

3. 分散表現を用いた整列順序に基づく書籍特徴の予測

ユーザが数冊の書籍を並べ、それを入力とした書籍整列順序に基づく推薦を行う。この書籍整列順序はユーザが与え、何らかの意図した順に並んでいるものとする。整列意図の例として、「コメディ要素が増加する順」「読みやすい順」などが考えられる。

本論文では、上記のような整列意図に沿った書籍を推薦するため、書籍特徴ベクトルを作成し、回帰分析を行う。得られた回帰式から、ある位置の書籍特徴ベクトルを予測することで、最も類似する書籍の推薦を行う。

整列順序に適した推薦を行うことで、ユーザが推薦された書籍と入力書籍の関連性がわかりやすいと考えられる。また、ユーザが意図していなかった意外な整列順序の意味をシステムが読み取ることで、serendipity の高い推薦を行うことができると考えられる。

3.1 書籍特徴ベクトルの作成

書籍の特徴を抽出する媒体として、本研究ではレビューに注目した。ユーザが自由に投稿することのできるレビューには、書籍自体の内容に触れる文章や、書籍を読んだことで得た感想が述べられている。よって、書籍レビューを用いることで、書籍の特徴を表すベクトルを作成できると考えた。レビューから書籍特徴ベクトルを作成するため、本論文では Paragraph vector [9] を利用する。

はじめに、レビューに対し形態素解析を行う。この際、単語を原型に戻し、レビュー中に含まれる人名を同一の記号に置き換えた。形態素解析には、辞書として mecab-ipadic-NEologd^(注1)を設定した MeCab [10] を利用した。

表 1 シャーロック・ホームズの冒険との類似書籍

順位	タイトル	著者	類似度
7	ボアロ登場	アガサ・クリスティー	0.70
15	ローマ帽子の謎	エラリー・クイーン	0.66
19	ブラウン神父の無心	G・K・チェスタトン	0.64
20	ミス・マーブルと十三の謎	アガサ・クリスティー	0.63
21	明智小五郎の事件簿 (1)	江戸川乱歩	0.63

次に、書籍特徴ベクトルを作成する。ある書籍に対し投稿されたレビューすべてを合わせて 1 文書とし、推薦候補であるすべての書籍から作られた文書の集合を全文書とする。この全文書に対し、Doc2Vec を用いて書籍特徴ベクトルを作成する。Doc2Vec のパラメータはそれぞれ、feature vector size は 300、window size は 15、min-count は 5 とした。

表 1 は「シャーロック・ホームズの冒険」と類似度の高い書籍を類似度の高い順に表している。この書籍特徴ベクトルは、4 節にて行う実験で作成した特徴ベクトルである。表中ではシャーロック・ホームズシリーズを除いており、順位はシャーロック・ホームズシリーズを含めた書籍の類似順位を表している。これらの書籍は、有名な探偵が事件を解決するという共通点を持っているため、適切な書籍特徴ベクトルを作成することができていると考えられる。

3.2 書籍特徴ベクトルの予測

3.1 節で作成した書籍特徴ベクトルから、回帰分析を用いてある位置の予測特徴ベクトルを作成する。回帰分析は、書籍特徴ベクトルの各要素に対し、それぞれ別個に行う。説明変数として、書籍の位置を整列順に並べた際の整数を与える。目的変数は、書籍特徴ベクトルの要素の値とする。回帰式の算出には、最小二乗法による線形回帰と、ガウスカーネルを用いたカーネルリッジ回帰の 2 つの方法を用いる。求めた回帰式から、予測する位置の数値を与えることで、ある位置の予測特徴ベクトルを算出する。位置 i の予測特徴ベクトルは、式 1 のように算出する。 $p_{i,1}$ は、線形またはカーネルリッジ回帰を用いて予測した 1 番目の要素の予測値である。

$$pred_i = [p_{i,1}, p_{i,2}, \dots, p_{i,n}] \quad (1)$$

線形回帰を行なった場合、特徴ベクトルの要素ごとに異なる決定係数と傾きを得る。図 3 は、要素ごとに異なる回帰式の例を表している。要素 A は高い決定係数を持ち、急な傾きを持つ一方で、要素 B の決定係数は低く、傾きも水平に近い。整列順序を表すにあたり、我々は決定係数が高く、傾きが大きな要素がより整列順序に関わっていると考えられる。よって、重みを式 2 として定義する。 w_1 は 1 番目の要素の重みを示している。

$$w = [w_1, w_2, \dots, w_n] \quad (2)$$

重みには、以下の 3 種類のうちいずれかを用いる。

- 決定係数
- 傾き
- 決定係数と傾きの乗算

3.3 書籍類似度の算出

3.2 節で作成した予測特徴ベクトルと、推薦候補書籍との類

(注1) : <https://github.com/neologd/mecab-ipadic-neologd>




図 3 要素による回帰式の違い

表 2 5 種類の手法

	回帰分析	類似度算出	重み
LC	線形	重み付き cos 尺度	決定係数
LM	線形	重み付き cos 尺度	決定係数・傾き
LG	線形	重み付き cos 尺度	傾き
L	線形	cos 尺度	-
K	非線形	cos 尺度	-

似度を算出する．類似度の算出には，以下の 2 種類の方法を用いる．

- 重み付き cos 尺度による類似度
- cos 尺度による類似度

書籍 j の書籍特徴ベクトル b_j と位置 i の予測特徴ベクトル $pred_i$ の重み付き cos 尺度は，式 3 のように表せる．これを，ユーザの入力書籍が存在しないすべての位置で行う．

$$\cos(pred_i, b_j) = \frac{\sum w_k p_{i,k} b_{j,k}}{\sqrt{\sum (w_k p_{i,k})^2} \sqrt{\sum (w_k b_{j,k})^2}} \quad (3)$$

cos 尺度は常に重み $w_k = 1$ とした場合の類似度を算出する．類似度算出には，2 種類の回帰分析と 2 種類の類似度，うち 1 種類の類似度に対し 3 種類の重みを組み合わせた 5 種類の手法が存在する (表 2)．

類似度を算出し，最も高い類似度を算出した書籍を推薦する．しかし，このとき近い位置には同一シリーズ，同一著者作品が連続する可能性が高い．よって，これを避けるために，同一著者の作品が推薦されないようフィルタリングを行なう．ある入力書籍の整列順が与えられた場合，その順序から入力書籍または既に推薦された書籍に存在する著者の作品が推薦書籍として選ばれた場合，その書籍は推薦せずに次に類似度の高い書籍を推薦する．

4. 整列意図に沿った書籍の推薦精度の評価

表 2 で表した類似度算出手法のうち，どの手法が最も正しく整列意図を組んだ推薦を行うことができるか検証するため，実験を行なった．今回の実験は，小説を対象としている．対象とする小説は，楽天ブックス^(注2)から集めた 238,135 冊の書籍である．また，読書メーター^(注3)から集めた，これらの書籍に対する 10,102,445 件のレビューを使用する．これらのレビューから，3.1 節で説明した書籍特徴ベクトルを作成する．

表 3 各手法に対する 3 種類の質問

No.	質問
Q1	書籍配列はあなたの意図した整列意図を汲んでいますか
Q2	推薦書籍に興味が出ましたか (推薦書籍ごと)
Q3	推薦書籍を読んだことがありますか (推薦書籍ごと)



図 4 システムの提示する 15 冊の書籍配列

4.1 比較手法

表 2 に示した 5 種類の提案手法との比較手法として，平均を用いた類似度算出手法を用いる．平均を用いた類似度算出手法 (AVG) は，ある位置の予測特徴ベクトルを決定する際，その位置から見て左右方向に存在する 2 つの入力書籍の書籍特徴ベクトルの平均を予測特徴ベクトルとする．片側だけに入力書籍が存在している場合は，その入力書籍の特徴ベクトルを，予測特徴ベクトルとする．予測特徴ベクトル決定後に関しては，cos 尺度を用いた類似度計算を行い推薦書籍を決定する．

4.2 実験方法

クラウドソーシングサービスであるクラウドワークス^(注4)を用いて，被験者 26 人 33 件^(注5)のデータを収集した．実験は，以下のような手順で実施した．

- (1) 被験者が検索を行い，我々の収集した 238,135 冊の書籍から 3 冊の入力書籍を選択．
- (2) 被験者が選択した入力書籍を意味のある順序に並び替え，その理由を回答．
- (3) システムが，3 冊の入力書籍と 12 冊の推薦書籍を含む 15 冊の書籍配列を，6 種類の手法を用いて提示 (図 4)．
- (4) 被験者がそれぞれの手法で提示された書籍配列に対し，3 種類の質問 (表 3) に回答．
- (5) 被験者が，システムの印象について自由に回答．

我々は，手順 2 において，いくつかの理由を回答とすることを禁止した．まず，「書籍の大きさ順」や「発売日の早い順」といった，書誌情報を元にする整列順序である．書籍レビューには，多くの場合書誌情報は含まれていない．よって，レビューを元に書籍特徴ベクトルを作成する提案手法では，書誌情報に基づく整列意図を読み取ることは不可能であるため，禁止している．また，「気に入った順」や「適当」といった，大雑把な意味も禁止している．これらの理由は，評価にあたり意図を捉えることが難しいためである．これらに加え「読んだ順」や「買った順」などの，システムでは判別不可能な順序も禁止している．

表 3 の質問は，Q1 は 1～7 の数字を高いほど整列意図に沿っているとして，7 段階の選択式で回答する．Q2，Q3 は推薦された書籍ごとに「当てはまる」「当てはまらない」の 2 択で回答する．

(注2) : <https://books.rakuten.co.jp/>

(注3) : <https://bookmeter.com/>

(注4) : <https://crowdworks.jp>

(注5) : 被験者は 1 人 4 回まで実験に参加可能

表 4 手法ごとの結果

	整列意図	興味冊数	既読冊数	推薦書籍間類似度
<i>LC</i>	4.44	6.52	1.09	0.36
<i>LM</i>	3.76	6.18	1.03	0.31
<i>LG</i>	3.88	6.03	1.03	0.32
<i>L</i>	4.64	6.76	1.12	0.41
<i>K</i>	4.48	6.33	0.91	0.42
<i>AVG</i>	4.52	6.67	1.12	0.45

表 5 ケース A:入力書籍が線形な関係に並ぶ場合 (10 件)

	整列意図	興味冊数	既読冊数	推薦書籍間類似度
<i>LC</i>	4.14	7.60	1.30	0.33
<i>LM</i>	3.14	6.90	1.60	0.29
<i>LG</i>	3.57	6.70	1.30	0.29
<i>L</i>	4.14	7.40	0.90	0.37
<i>K</i>	4.28	6.90	1.00	0.39
<i>AVG</i>	4.00	7.00	1.00	0.41

表 6 ケース B:入力書籍が水平に近い関係に並ぶ場合 (19 件)

	整列意図	興味冊数	既読冊数	推薦書籍間類似度
<i>LC</i>	4.40	6.05	1.10	0.37
<i>LM</i>	3.67	5.84	0.84	0.31
<i>LG</i>	3.67	5.53	1.00	0.33
<i>L</i>	4.60	6.31	1.37	0.43
<i>K</i>	4.33	6.00	0.95	0.44
<i>AVG</i>	4.67	6.37	1.32	0.46

4.3 結果と考察

実験結果は、表 4 のようになった。整列意図は各手法における Q1 に対する評価の平均を表し、高いほど整列意図を汲んだ推薦であることを示す。興味は、推薦された書籍のうち興味の湧いた推薦書籍数の平均冊数を表す。既読は、推薦された書籍のうち既に読んだことがある書籍の平均冊数を表す。推薦書籍間類似度は、推薦された 12 冊の書籍から、総当たりで 2 冊ずつ類似度を比較した平均類似度を示している。このため、推薦された書籍の多様性を示している。

まず、被験者が入力書籍として選んだ書籍のうち、既に読んだことのある書籍は 3 冊中平均 2.76 冊となった。よって、多くの被験者は既に読んだ経験のある書籍を入力としている。このことから、興味や既読冊数といった観点に基づく被験者の回答は妥当なものである。

整列意図において、最も高い値を示したのは *L* である。次に、*AVG*、*K*、*LC*、*LG*、*LM* の順に高い値を示した。類似度算出の際、重みを与えた手法の値が特に低くなっている。興味において最も高い値を示したのは、整列意図と同じく *L* である。次に、*AVG*、*LC*、*K*、*LG*、*LM* の順に高い値を出した。整列意図と興味の高い値を示した手法の順位は、よく似ている。我々は、被験者が興味のある書籍が多い場合に、整列意図に高い値を与えた可能性があると考え、2 つの相関関係を調べた。相関係数は 0.398 であり、整列意図と興味の間には、弱い相関が見られた。

既読書籍はすべての手法についてほぼ 1 であり、手法間に差

は見られなかった。推薦書籍間類似度では、最も高い値を出した手法は *AGV* である。*AGV* では、入力書籍同士の間の位置に推薦される書籍の予測特徴ベクトルがすべて同一になるため、高い類似度を示すと考えられる。その他の手法では、*AGV* に比べ幅広い書籍を推薦している。

我々は、より細かい分析を行うため、データを 3 つのケースに分割した。分割方法は以下の通りである。

- A) 入力書籍が線形に並ぶ可能性のある関係 ($Y + 0.05 < X$).
- B) 入力書籍はほぼ水平に並んでいるが、次元単位には線形に並んでいる可能性のある関係 ($Y - 0.05 < X \leq Y + 0.05$).
- C) 入力書籍が非線形に並んでいる関係 ($X \leq Y - 0.05$).

X は入力書籍 3 冊の 2 冊ずつ総組み合わせの類似度であり、 Y は両端の入力書籍の類似度を示している。

表 5 はケース A の結果である。ケース A には 10 件のデータが含まれている。全データの平均に比べ、すべての手法においてわずかに整列意図の値が低くなった。また、整列意図が最も高い手法は *K* になっている。加えて、*LC* と *L* の整列意図が同じ値を示している。この理由として、入力書籍が線形に並んでいるため、多くの次元において比較的高い決定係数を示したためと考えた。全データを用いた場合の決定係数の平均は 0.503 であったが、ケース A では決定係数の平均は 0.556 となった。よって、決定係数を重みとして用いた場合の影響が若干弱まり、線形に近くなったのだと考えられる。また、ケース A における整列意図と興味の相関係数は 0.472 となり、やや正の相関が見られた。ケース A では、ケース分割前よりも、相関が高くなっている。

表 6 はケース B の結果である。ケース B には 19 件のデータが含まれている。ケース B の値は、ケース A ほど分割前とあまり変化が生まれなかった。分割データのうち、半分以上のデータがケース B に分類されたため、変化が生まれなかったと考えられる。しかし、ケース B における整列意図と興味の相関係数は 0.484 となり、やや正の相関が見られた。ケース A 同様に、ケース分割前よりも相関が高くなっている。

ケース C には、4 件のデータが分類された。ケース C においては、データ数が非常に少なくなってしまったため、詳細な分析は断念した。ケース C に分類されるデータが少なくなった理由として、被験者が真面目に書籍を配列したためと考えた。被験者がある意図を想定して配列したため、入力書籍が何らかの線形な関係になったと考えられる。被験者がランダムに入力書籍を決定していた場合、ケース C への分類数はより増加すると考えられる。

ケース A、B において興味と整列意図にやや相関が見られたことから、興味のある書籍が多い場合に、整列意図に高い値をつける傾向があると考えられる。よって、推薦結果が被験者の整列意図を汲んでいたかという点に関し、整列意図の指標は我々の意図と若干異なる意味を示していた可能性がある。

また、すべての場合において重み付けを行なった手法 (*LC*、*LM*、*LG*) の整列意図は低い値を示した。この理由として、今回用いた Paragraph Vector が、LDA のトピックのように各要素がわかりやすい書籍の要素を示しているとは限らないという

表 7 整列意図の値が低かった整列理由

整列理由	<i>LC</i>	<i>LM</i>	<i>LG</i>	<i>L</i>	<i>K</i>	<i>AVG</i>
内容が分かりやすいものから不可解なものの順番に並べました	1	1	1	1	1	1
囲碁を題材にした小説で、小学生が対象のものから、大人向けのものまでの順番で並べられる	2	2	1	1	1	1
主人公の生きた時代が新しくなる	2	2	2	2	3	2

点があげられる。たとえば、今回作成した書籍特徴ベクトルにおいて、ある要素は書籍のファンタジー要素に深く関わっており、またある要素は少しだけファンタジー要素を表すことに関わっているということが考えられる。したがって、各要素に別個に重み付けを行なった場合、書籍要素を表すベクトル要素のバランスが崩れてしまう可能性がある。このような理由によって、重み付けを行なった手法はすべてのケースで低い値を出したと考える。

また、各被験者が回答した整列理由についての分析を行なった。いくつかの整列理由では、すべての手法において Q1 の整列意図の値が 4 を下回った。表 7 は Q1 の値が低かった整列理由の例を示している。これらの例に共通しているのは、どれも書籍の踏み込んだ内容に関連する事柄に言及している点である。これらの整列意図の値が低くなった原因として、レビューを利用し書籍特徴ベクトルを作成したことが考えられる。多くのレビューでは、作品の大まかなストーリーや大雑把な印象に触れ、踏み込んだ内容に触れることは非常に少ない。よって、レビューを元にした場合では、意図して踏み込んだ内容を記述した点を抽出しない限り、提案手法ではそれらの意味を理解することが難しいと考えた。逆に、ジャンルの含有度のようにわかりやすい意味であれば、システムは意味を理解しやすいと考える。

今回の実験では、*L* と *AVG* が最もよく整列意図を理解していると考えた。この 2 つを比較すると、*L* の方が推薦書籍間類似度が全体的に低い値を示している。このことから、*L* の方が *AVG* よりもバラエティに富んだ種類の書籍を推薦できていることがわかる。偏った書籍よりも、さまざまな書籍を推薦した方が意外性の高い書籍を発見する可能性は高く、我々の serendipity の高い推薦を目指す目的と合致している。よって、我々は *L* の方が *AVG* より優れた推薦ができたと考えている。

また、今回手法間の整列意図の相関についても調査した。表 8 は、全データを用いた際の各手法間における整列意図の相関係数を示している。ほぼすべての手法間において、高い正の相関関係にある。この中で、*L* について注目した際、最も相関が強いのは *LC* であり、*AVG* は 3 番目に高い相関を示している。このことから、*L* が整列意図を理解している時、相対的に必ずしも *AVG* も整列意図を理解しているとは限らず、若干異なる推薦を行なっていることがわかる。

5. 提案手法による意外性と説明性の評価

書籍特徴ベクトルを用いない他の推薦手法と比較し、提案手法の有効性を検証するため実験を行なった。本節の実験においても 4 節と同様に小説を対象としている。しかし、投稿レビュー数があまりに少ない場合、適切な書籍特徴ベクトルを作

表 8 手法間の整列意図における相関

	<i>LM</i>	<i>LG</i>	<i>L</i>	<i>K</i>	<i>AVG</i>
<i>LC</i>	0.72	0.72	0.87	0.74	0.78
<i>LM</i>		0.75	0.73	0.66	0.66
<i>LG</i>			0.74	0.75	0.69
<i>L</i>				0.85	0.76
<i>K</i>					0.74

表 9 推薦された書籍に対する 3 種類の質問

No.	質問
Q1	推薦書籍を既に知っていましたか
Q2	推薦書籍に興味が出ましたか
Q3	入力書籍からなぜ推薦されたのか部分的にでも関連性がわかりますか

ることが難しい。よって、推薦精度を向上させるため、4 節で用いた書籍のうち投稿レビュー数が 10 以上である 94,552 冊を対象とした。これらの書籍に対し投稿されたレビューの総数は 9,651,053 件である。

5.1 比較手法

比較手法として、アソシエーションルールを用いた推薦を行う。あるユーザがレビューを投稿した書籍は、そのユーザにとって好ましい書籍であると仮定する。あるユーザが好む全書籍群を 1 件の嗜好データとし、嗜好データに対しアソシエーションルールを適用することで、確信度の高い書籍を推薦する。本実験においては、3 冊の入力を行うため、最長で {3 冊の入力書籍} ⇒ {推薦書籍} という長さ 4 のルールが生成されることとなる。

3.3 節で述べた通り、提案手法において同一著者作品が推薦されないようフィルタリングを行なっている。これにより、比較手法のみ入力書籍と同一著者の作品や同一シリーズが溢れる可能性がある。このことから、提案手法に条件を近づけるため、比較手法で推薦された書籍においても同様のフィルタリングを行なった。

また、比較手法では推薦される書籍の順序に確信度順以外の意味が存在せず、被験者からはその意味も分かり辛い。よって、推薦書籍を提示する際、提案手法比較手法共にランダムな順序に並び替えた書籍集合を提示する。

5.2 実験方法

4.2 節同様、クラウドソーシングを用いて被験者 31 人 37 データを収集した。実験は、以下のような手順で実施した。

- (1) 被験者が検索を行い、我々の収集した 94,552 冊の書籍から 3 冊の入力書籍を選択。
- (2) 被験者が選択した入力書籍を意味のある順序に並び替え、その理由を回答。

表 10 質問ごとの平均冊数と割合

		比較手法	提案手法
Q1	既知	4.84 冊	3.03 冊
Q2	既読・元から興味あり	3.56 冊	2.30 冊
	新しく興味が湧いた	3.76 冊	6.24 冊
Q3	関連	4.81 冊	7.78 冊
Q1&Q2	既知かつ新しく興味が湧いた	0.11	0.14

(3) システムが、提案手法および比較手法に基づき、それぞれ 12 冊の推薦書籍集合を提示。

(4) 被験者が 2 つの手法で提示された書籍集合に含まれる各書籍について、3 種類の質問 (表 9) に回答。

(5) 被験者が、システムの印象について自由に回答。

表 9 の回答は、Q1、Q3 が「当てはまる」または「当てはまらない」の 2 択。Q2 のみ、「既に読んだことがある・元から興味があった」、「新しく興味が湧いた」または「興味無し」の 3 択である。

また、この実験においても 4.2 節と同様に、整列順序の意図に制限を行なっている。

5.3 結果と考察

結果は表 10 のようになった。提案手法、比較手法において、それぞれの質問に対して回答された平均冊数と、Q1 で既知と回答した書籍のうち Q2 で新しく興味が湧いたとした書籍の割合の平均を示している。

まず、比較手法で用いられたアソシエーションルールの長さごとの平均は、表 11 のようになった。最も多く用いられたルールの長さは 3 であり、次いで長さ 4 のルールを用いている。長さ 2 のルールはほとんど用いられることがなかったため、比較手法による出力は、複数の入力書籍に基づくものであり、比較対象として妥当である。

次に、被験者が入力書籍として選んだ書籍のうち、既に読んだことのある書籍は 3 冊中平均 2.46 冊となった。これは 4.3 節より若干低い値となったが、過半数を超えているため、十二分に多くの被験者は既に読んだ経験のある書籍を入力していると考えられる。このことから、既知や興味、関連性といった観点に基づく被験者の回答は妥当なものである。

Q1 では、提案手法がより低い値を示した。比較手法であるアソシエーション分析を用いた推薦では、基本的により多くのユーザが好む組み合わせから推薦する書籍を決定する。よって、多くのユーザが好む知名度が高いベストセラー書籍などが推薦されたと考えられる。これに対し提案手法では、書籍レビューによって表される書籍の内容や感想を元に推薦書籍を決定するため、単純な知名度の高さは考慮されない。よって、提案手法は比較手法に比べ、被験者にとって未知な書籍を推薦することができたと考えられる。

Q2 においては、「既読・元から興味あり」では比較手法が高い値を示しているが、「新しく興味が湧いた」では提案手法の方が高い値を示した。「既読・元から興味あり」と「新しく興味が湧いた」に関しては、既知書籍の多さが多く関わっていると予想できる。そのため、既知書籍の多い比較手法は「既読・元か

表 11 アソシエーションルールの長さごとの平均使用回数

ルールの長さ	平均
2	0.36
3	6.88
4	4.75

ら興味あり」の値が高くなり、未知な書籍の多い提案手法では「新しく興味が湧いた」の値が高くなっていると考えられる。また、興味ありに含まれる 2 項目の値の合計値は比較手法が 7.32 冊、提案手法が 8.54 冊と、提案手法の方が高い値を示している。よって、提案手法の方がより被験者にとって意外性があり興味のある書籍を推薦できていると考えられる。

Q3 では、提案手法がより高い値を示している。今回提案手法では、推薦書籍の順序をランダムに並び替えているが、内容的な関連性は変わらないため、ある程度高い値を示したと考えられる。このため、比較手法より優れた説明性を兼ね備えていると考えられる。また、ランダム化する前の整列順序で推薦した場合は、より関連性がわかりやすくなる可能性がある。

これに加え、Q1 で既知と回答された書籍のうち、Q2 で「新しく興味が湧いた」と答えられた書籍の割合の平均を計算した。提案手法では 0.14、比較手法では 0.11 と、提案手法の方が若干高い値を示した。このことから提案手法を用いると、既存手法より既に知っていた書籍に対し新たな興味を発見することができると考えられる。

以上のことから、基本的に提案手法を用いることで、意外性と説明性が既存手法より高い推薦を行える可能性があると考えられた。しかし、被験者からの自由記述意見として、以下のようであった。

- 少し慣れるまでに時間がかかる。
- 現状でも刺激になってちょっと面白いと思う。最初の 3 冊がもっと自由に選べるとさらに役に立つのではないと思う。

これらの意見は、主に入力書籍の整列方法を大幅に制限したことが原因となり現れたと考えられる。提案手法では、整列方法によっては適切な推薦が難しいため制限を行なった。しかし、システムの使いやすさや利便性といった観点への配慮がおろそかになってしまった。意外性や説明性だけでなく、システムとしての評価を行う際は、この点にも注意する必要があると考えられる。改善点として、整列意図の制限を無くすことや、入力書籍の数を 2 冊に減らすことがあげられる。だが、ユーザがある程度自由に入力書籍を決定する場合、意外性や説明性が保たれるか、調査を行う必要がある。

6. ま と め

本論文では、ユーザの書籍整列順序に基づき serendipity と explainability を考慮した推薦手法を提案した。ユーザの整列意図に注目することで、ユーザにとってなぜ書籍が推薦されたかわかりやすく、またユーザの意図していなかった意外な整列意図を汲み取ることで意外な書籍が推薦されることを目的とした。

提案手法では、書籍レビューから書籍特徴ベクトルを作成し、

ベクトル要素ごとに回帰分析を行うことで、ある位置の特徴ベクトルを予測し、推薦候補書籍との類似度を算出することで書籍推薦を行なった。評価実験として、どの手法が最も正しく整列順序を理解しているか確かめるため、提案手法内の5つの手法と比較手法を用いて比較実験を行なった。また、整列順序を用いないアソシエーション分析を用いた推薦との比較実験を行なった。

これらの結果、通常の線形回帰を用いた重み付けをしない手法が、最もよく整列順序を理解できることがわかった。重み付けを行なった場合、書籍要素のバランスを崩すことで、整列意図を理解できなくなってしまう可能性がある。これに加え、提案手法では既存手法に比べ、ユーザにとって未知かつ興味のある書籍を推薦できる可能性があるとわかった。しかし、入力書籍の選び辛さという問題点が存在することもわかった。

今後の課題として、提案手法を実装したシステムを用い、さらに他の推薦システムとの比較実験を行うことで、提案手法が意外性や説明性の観点から優れているかより正確に調査することを考えている。また、提案手法を実装したシステムの使いやすさや利便性といった観点において、他の推薦システムと比較を行うことを考えている。

謝辞 本研究の一部は、平成30年度科研費基盤研究(C)(課題番号:18K11551)によるものです。ここに記して謝意を表すものとします。

文 献

- [1] Jonathan L. Herlocker, Joseph A. Konstan, Loren G. Terveen, and John T. Riedl. Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.*, 22(1):5–53, January 2004.
- [2] Yehuda Koren. Tutorial on recent progress in collaborative filtering. In *Proceedings of the 2008 ACM Conference on Recommender Systems*, RecSys '08, pages 333–334, New York, NY, USA, 2008. ACM.
- [3] Mouzhi Ge, Carla Delgado-Battenfeld, and Dietmar Jannach. Beyond accuracy: Evaluating recommender systems by coverage and serendipity. In *Proceedings of the Fourth ACM Conference on Recommender Systems*, RecSys '10, pages 257–260, New York, NY, USA, 2010. ACM.
- [4] Sharon Givon and Victor Lavrenko. Predicting social-tags for cold start book recommendations. In *Proceedings of the Third ACM Conference on Recommender Systems*, RecSys '09, pages 333–336, New York, NY, USA, 2009. ACM.
- [5] Daichi Minami and Taketoshi Ushijima. A collaborative filtering method based on empathy with reviewers. In *Proceedings of the 11th International Conference on Ubiquitous Information Management and Communication*, IMCOM '17, pages 33:1–33:6, New York, NY, USA, 2017. ACM.
- [6] Yidan Liu, Min Xie, and Laks V.S. Lakshmanan. Recommending user generated item lists. In *Proceedings of the 8th ACM Conference on Recommender Systems*, RecSys '14, pages 185–192, New York, NY, USA, 2014. ACM.
- [7] Kenta Oku and Fumio Hattori. User evaluation of fusion-based approach for serendipity-oriented recommender system. In *Proceedings of the Workshop on Recommendation Utility Evaluation: Beyond RMSE (RUE 2012)*, pages 39–44, 2012.
- [8] Stephen J. Green, Paul Lamere, Jeffrey Alexander, François Maillet, Susanna Kirk, Jessica Holt, Jackie Bourque, and

Xiao-Wen Mak. Generating transparent, steerable recommendations from textual descriptions of items. In *Proceedings of the Third ACM Conference on Recommender Systems*, RecSys '09, pages 281–284, New York, NY, USA, 2009. ACM.

- [9] Quoc V. Le and Tomas Mikolov. Distributed representations of sentences and documents. *CoRR*, abs/1405.4053, 2014.
- [10] Taku Kudo, Kaoru Yamamoto, and Yuji Matsumoto. Applying conditional random fields to japanese morphological analysis. In *In Proc. of EMNLP*, pages 230–237, 2004.