

# 書籍レビューテキストから生成した評価軸と トピックモデルを用いたハイブリッド推薦手法の有効性

北原 将平<sup>†</sup> ジェプカ ラファウ<sup>†</sup> 荒木 健治<sup>†</sup>

**概要**：近年、消費者生成メディアの普及により、商品の口コミが大量に得ることが可能となった。これらのレビューテキストは構造化されていないが、商品に関する有用な情報が書かれていることが多い。本稿では、商品のレビューテキストから半自動的に生成した評価軸とトピックモデルを用いたハイブリッド型推薦手法を新たに提案する。評価実験では、評価値予測のタスクにおいて従来手法との比較を行い、提案手法の有効性を確認した。

**キーワード**：推薦システム、トピックモデル、情報抽出、評価軸、ハイブリッド型推薦

## 1. はじめに

近年、情報通信機器の普及により、個人が情報を容易に閲覧、蓄積、発信できる時代になった。しかし、一方で情報過多の問題が発生している。情報過多とは、大量の情報により、必要な情報を見つけ出すことが困難な状況を指す。

このような状況を打破するために、推薦システムの必要性がますます増大している。推薦システムの定義は、Konstan ら[1]による“どれに価値があるかを特定するのを助ける道具”という定義を利用する。実際に、Amazon や楽天といった企業では推薦システムを利用し、電子商取引を行っている。

これらの背景から、利用者の嗜好を正確に予測することは推薦システムにとって重要な課題であると考えられる。ユーザが商品に付与した評価値を予測するタスクに取り組んでいる初期の研究としては、既存のユーザの履歴を用いる協調型推薦がある[2]。また、協調型推薦はユーザベースとアイテムベースの2種類に分類され、Wang らはこれらを組み合わせた手法を提案している[3]。一般に協調型推薦では、評価値情報のみを用いて推薦を行うため、商品の推薦精度が低下するという課題がある。そのため、予測対象の商品情報を用いる内容ベース型推薦手法と協調型推薦手法を組み合わせるハイブリッド型推薦手法の研究が盛んに行われている。

評価値予測のタスクにおけるハイブリッド型推薦手法の研究では、映画のレビューテキストに tf-idf 法を用いて、評価値の予測を行う岡田らの手法がある[4]。岡田らの手法では表層語の影響により、予測精度が低くなるという課題がある。そこで北原らは書籍のレビューテキストにトピックモデル[5]を用いて潜在的意味を考慮することで予測精度の向上を試みた[6]。北原らの手法では、「イラストが綺麗」や「展開が分かりづらい」といった書籍の属性語に対する評価表現を考慮していないため、精度が低下するという課題があった。これらの属性語に対する評価表現は多様な

表現で大量にあるため、「表紙絵が素敵」、「挿絵がかわいい」といった表現は「絵」の評価軸に関する評価表現として、まとめて取り扱うことが望ましいと考えられる。

評価値予測タスクにおいて評価軸を利用する手法には Ganu らの手法があり、レストランの評価値予測を行っている[7]。Ganu らの手法では、評価軸を独自に設定して評価実験を行っており、評価軸の数も少ないという課題がある。

評価軸構築に関する研究としては、係り受け情報と相互情報量を用いたグエンらの手法があり、評価軸の分類を行っている[8]。また、金兵らは商品レビューを利用した評価軸の自動構築を行っている[9]。

本研究の目的は、書籍を対象とした推薦システムの評価値予測タスクにおいて、予測精度を向上させることである。書籍を対象とする推薦タスクの場合、Ganu らの手法のように独自に評価軸を設定することが難しい。なぜなら書籍という商品カテゴリは嗜好品の一種のため、ユーザの評価基準が曖昧であり、評価軸の総数も不透明だからである。そこで金兵らの手法を用いて、レビューテキストから書籍の評価軸を半自動的に作成することで課題の解決を試みる。

本稿では、「書籍の内容と評価軸の傾向が類似している書籍は評価傾向も類似する」という仮定に基づき、書籍のレビューテキストから生成した評価軸とトピックモデルを用いたハイブリッド推薦手法を適用し、有効性の確認を行う。

本稿の構成は以下の通りである。まず2章では、関連研究について述べる。3章では、提案手法について述べる。4章では、評価実験について述べる。5章では評価実験における評価値予測タスクの結果と考察について述べる。最後に6章で結論と今後の課題について述べる。

## 2. 関連研究

本実験でベースラインとして比較するユーザベースとアイテムベース型の協調型推薦手法について説明を行う。また、トピックモデルを用いた北原らの手法の説明も行う。

<sup>†</sup> 北海道大学大学院情報科学研究科  
Graduate School of Information Science and Technology, Hokkaido University.

まず、協調型推薦手法では、与えられた評価値行列をインプットとして、特定のユーザの対象アイテムに対する評価値をアウトプットとして生成する。このとき、ユーザ数を $K$ 、アイテム数を $M$ とすると、評価値行列 $Q$ は $K$ 行 $M$ 列で表現できる。また、図1で示すように、評価値行列の要素は評価値であり、ユーザ $k$ のアイテム $m$ に対する評価値は $x_{k,m}$ と表現することができる。

評価値行列の行ベクトルはユーザの特徴ベクトルであるので、ユーザの特徴ベクトルを $\mathbf{u}$ とすると、式(1)で表現できる。

$$Q = [\mathbf{u}_1, \dots, \mathbf{u}_k]^T, \mathbf{u}_k = [x_{k,1}, \dots, x_{k,M}] \quad (k = 1, \dots, K) \quad (1)$$

同様にして、評価値行列の列ベクトルはアイテムの特徴ベクトルであるので、アイテムの特徴ベクトルを $\mathbf{i}$ とすると、式(2)で表現できる。

$$Q = [\mathbf{i}_1, \dots, \mathbf{i}_m]^T, \mathbf{i}_m = [x_{1,m}, \dots, x_{K,m}]^T \quad (m = 1, \dots, M) \quad (2)$$

	$\mathbf{i}_1$	...	$\mathbf{i}_m$	...	$\mathbf{i}_M$
$\mathbf{u}_1$			$x_{1,m}$		
⋮					
$\mathbf{u}_k$	$x_{k,1}$		$x_{k,m}$		$x_{k,M}$
⋮					
$\mathbf{u}_K$			$x_{K,m}$		

図1 評価値行列

### 2.1 ユーザベースの協調型推薦

ユーザベースの手法では、図2で示すように、評価傾向の類似するユーザ（以下、最近傍と呼ぶ）の評価値を利用して、対象ユーザの評価値を予測する。最近傍は調整コサイン類似度を用いて算出される。ユーザ $\mathbf{u}_k$ とユーザ $\mathbf{u}_a$ の調整コサイン類似度を $S_u(\mathbf{u}_k, \mathbf{u}_a)$ とすると、ユーザ $k$ のアイテム $m$ に対する予測評価値 $X_u$ は式(3)になる。

$$X_u = \bar{u}_k + \frac{\sum_a S_u(\mathbf{u}_k, \mathbf{u}_a)(x_{a,m} - \bar{u}_a)}{\sum_a |S_u(\mathbf{u}_k, \mathbf{u}_a)|} \quad (3)$$

	$\mathbf{i}_1$	...	$\mathbf{i}_m$	...	$\mathbf{i}_M$
$\mathbf{u}_k$			$x_{k,m}$		
⋮					
...					
...					
...					

図2 ユーザベースの評価値予測

ただし、ユーザベクトル間の類似度を算出する際には、共通に評価されているアイテムの評価値のみを用いる。また、類似度が0の場合には、ユーザの平均評価値 $\bar{u}_k$ を予測評価値とする。

### 2.2 アイテムベースの協調型推薦

アイテムベースの手法では、2.1のユーザベースの手法と同様に、図3で示すように、評価傾向の類似するアイテムの評価値を利用する。アイテム $\mathbf{i}_m, \mathbf{i}_b$ の調整コサイン類似度を $S_i(\mathbf{i}_m, \mathbf{i}_b)$ とすると、予測評価値 $X_i$ は式(4)となる

$$X_i = \bar{u}_k + \frac{\sum_b S_i(\mathbf{i}_m, \mathbf{i}_b)(x_{k,b} - \bar{u}_k)}{\sum_b |S_i(\mathbf{i}_m, \mathbf{i}_b)|} \quad (4)$$

	$\mathbf{i}_m$	...	類似度の降順		
$\mathbf{u}_1$					
⋮					
$\mathbf{u}_k$	$x_{k,m}$				
⋮					
$\mathbf{u}_K$					

図3 アイテムベースの評価値予測

### 2.3 北原らの手法

北原らの手法では、2.2で述べたアイテムベースの手法におけるアイテム間の類似度を算出する際に、LDA (Latent Dirichlet Allocation)を利用する。

#### 2.3.1 Latent Dirichlet Allocation (LDA)

LDAとは、確率的言語モデルの一種であり、文書や単語には表層的に表れない潜在的な意味（トピック）を仮定することで、文書や単語間の関連性を推定することができる。

トピック数を $T$ 、文書数を $D$ 、文書 $j$ の単語数を $N_j$ とする。また、トピック $T$ における単語の出現頻度を表すベクトルを $\phi_t$ 、文書 $j$ におけるトピックの出現確率を $\theta_j$ と表し、文書 $j$ における $i$ 番目に出現した単語を $w_{j,i}$ 、文書 $j$ における $i$ 番目に出現した潜在トピックを $z_{j,i}$ とすると、文書の確率的生成モデルは式(5),(6),(7)より算出される。

$$\theta_j \sim \text{Dir}(\alpha) \quad (j = 1, \dots, D) \quad (5)$$

$$\phi_t \sim \text{Dir}(\beta) \quad (t = 1, \dots, T) \quad (6)$$

$$z_{j,i} \sim \text{Multi}(\theta_j) \text{ and } w_{j,i} \sim \text{Multi}(\phi_{z_{j,i}}) \quad (i = 1, \dots, N_j) \quad (7)$$

$\alpha$ と $\beta$ はディリクレ分布のハイパーパラメータである。本実験ではPythonのライブラリであるgensimを使用し、 $\alpha$ と $\beta$ はデフォルトの値を利用する。

### 2.3.2 LDA を用いたアイテムの特徴ベクトルの作成

LDA を適用することで、文書ごとのトピック分布を生成することが可能になる。北原らの手法では、このトピック分布を利用して、アイテムの特徴ベクトルを作成する。

まず、前処理として、それぞれの書籍に対する全てのレビューテキストの集合を Bag of Words で表現する。この際に、MeCab[10]を用いて形態素解析を行い、品詞を制限する。Bag of Words のモデルでは、内容語に注目することによる性能の向上が多く報告されている。よって、Bag of Words を構成する品詞は、内容語である「名詞」、「形容詞」、「動詞」そして「副詞」の4種類に制限し、これらの品詞以外の単語は除外する。この文書集合を入力として、LDA を適用する。出力はそれぞれの文書に対するトピック分布で表現できる。これより、ある書籍*i*のレビュー文書*d(i)*のトピック分布 $P_{d(i)}$ は式(8)で表現できる。評価実験におけるトピック数*T*は、予備実験で精度の最も高かった*T=20*を設定する。

$$P_{d(i)} = [p_1, \dots, p_T] \quad (\sum p_t = 1) \quad (8)$$

### 2.3.3 予測評価値の算出

2.3.2 で定義したトピック分布をアイテムの特徴ベクトルとみなすことで、図4のようにアイテム間の類似度を算出し、評価値を予測することができる。

アイテム $\mathbf{i}_m, \mathbf{i}_b$ の類似度 $S_t(\mathbf{i}_m, \mathbf{i}_b)$ はトピックの分布ベクトル $P_{d(\mathbf{i}_m)}$ と $P_{d(\mathbf{i}_b)}$ のコサイン類似度を用いて算出できる。よって、LDA を用いたアイテムベース (トピックアイテムベースと呼ぶ) の予測評価値 $X_{ti}$ は式(9)により定義される。

$$X_{ti} = \bar{u}_k + \frac{\sum_b S_t(\mathbf{i}_m, \mathbf{i}_b)(x_{k,b} - \bar{u}_k)}{\sum_b |S_t(\mathbf{i}_m, \mathbf{i}_b)|} \quad (9)$$




図4 トピックアイテムベースの評価値予測

## 3. 提案手法

本稿では、2.3 で述べた北原らの手法におけるアイテム間の類似度を算出する際に、レビューテキストから作成する評価軸を併用する手法を新たに提案する。

評価軸とは、「ストーリー展開」、「絵」、「登場人物」といった書籍に関する評価指標である。また、評価軸は属性語

の集合で表現される。ここで、属性語とは書籍に備わっている性質や特徴を指す。

評価軸を作成するには、2つの段階を必要とする。1つは属性語辞書と評価表現辞書を作成する段階である。もう1つは作成した辞書に基づき、属性語のクラスタリングを行い、評価軸を作成する段階である。

最後に作成した評価軸を用いて、アイテムの特徴ベクトルを作成し、評価値の予測を行う。図5に提案手法における評価値予測までの処理過程を示す。

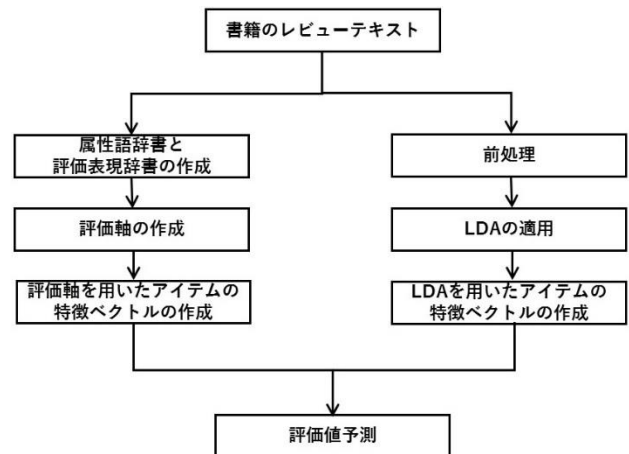


図5 提案手法の処理過程

### 3.1 属性語辞書と評価表現辞書の作成

まずは書籍のレビューテキスト全体に対してCaboCha[11]を用いて係り受け解析を行う。その後、共起パターンと頻度情報を用いて、属性語の辞書を作成する。書籍のレビューテキストに対して、<書籍>の<属性語>という共起パターンを用いて属性語を抽出する。このとき、共起パターンの<書籍>の部分は日本語 WordNet[12]の同義語を用いてクエリの拡張を行う。

属性語と評価表現の抽出に関する小林らの研究によると、属性語では名詞が最も頻度の高い品詞であり、評価表現では形容詞と形容動詞が頻度の高い品詞であるという報告がされている[13]。これより本手法でも属性語の品詞は名詞に限定し、評価表現は「形容詞」と「名詞 - 形容動詞語幹」を含む場合に限定する。

そのうえで、抽出頻度が50以上の属性語に対して、書籍の属性語であるかを人手で判定し、被験者の半数以上が属性語と判定した場合に、書籍の属性語として属性語辞書に追加する。被験者は理系の大学生7名であり、 $\kappa$ 値の平均値は0.481で中等度の一致率であった。

次に獲得した属性語との共起パターンを用いて、評価表現を抽出する。使用した共起パターンは、以下の2種類のパターンである。

- ・ <属性語> {が/は/も/に/を} <評価表現>
- ・ <評価表現> <属性語>

その後、属性語との共起頻度が 200 以上の評価表現を抽出し、日本語評価極性辞書に登録されている表現を評価表現辞書に追加する[13][14]。このとき、日本語評価極性辞書に未登録の評価表現に関しては人手で判定を行う。

作成した辞書の語彙数は、属性語辞書で 132 語、評価表現辞書で 624 語であった。表 1 と表 2 に作成した属性語辞書と評価表現辞書の例を示す。

表 1 属性語辞書の例

表題, カバー, 文字, 登場人物, 背景, キャラクター, 帯, 表紙絵, デザイン, 表紙裏, 作風, 序章, 描写
--

表 2 評価表現辞書の例

肯定表現	良い, 読みやすい, ほほえましい, スムーズ, 格好いい, 魅力的, 可愛らしい, 奥深い
否定表現	悪い, 理屈っぽい, わざとらしい, 不自然, つまらない, 読みにくい, 寂しい, 陰鬱

### 3.2 評価軸の作成

評価軸の作成には金兵らの手法を用いる。金兵らの手法では、K-means を用いて属性語のクラスタリングを行い、評価軸を作成する。このとき属性語と評価表現間の距離は式(10)で定義される。

$$tfidf_{i,j} = tf_{i,j} \cdot idf_i \quad (10)$$

$$tf_{i,j} = \frac{n_{i,j}}{\sum_{k=1}^K n_{k,j}} \quad (11)$$

$$idf_i = \log \frac{F}{F_i} \quad (12)$$

$n_{i,j}$  は評価表現  $e_i$  と属性語  $f_j$  が係り受けになる頻度であり、 $F$  は属性語の総数、 $F_i$  は評価表現  $e_i$  と共起する属性語の頻度である。式(10)は「属性語と評価表現の相関関係」を表す尺度とみなせる。

これより、式(10)で定義する評価表現との距離を要素とする属性語の特徴ベクトル  $e_i$  は式(13)で定義される。

$$e_i = [tfidf_{i,1}, tfidf_{i,k}, \dots, tfidf_{i,K}] \quad (13)$$

式(13)で表現できる属性語の特徴ベクトルに対して、K-means を用いて属性語のクラスタリングを行うことで評価軸を作成する。表 3 に作成した評価軸の例を示す。

表 3 評価軸の例

評価軸 4	描写, 構想, 表現, 背景, 伏線, 設定, ストーリー展開, 構造
評価軸 8	表紙, 扉絵, 装丁, デザイン, 裏表紙, 挿絵, 写真, イラスト, カバー裏, 絵

評価軸 9	ラスト, クライマックス, 中盤, 場面, 結末, 後半, 終盤, 結論
-------	--------------------------------------

### 3.3 評価軸を用いたアイテムの特徴ベクトルの作成

3.2 で作成した評価軸を用いて、アイテム  $i$  の特徴ベクトルを定義する。

評価軸の総数 (属性語のクラスタ数) を  $A$ 、アイテム  $i$  における評価軸  $a$  の極性の割合を  $r_{i,a}$  とすると、評価軸を用いたアイテム  $i$  の特徴ベクトル  $R_i$  は式(14)のように定義される。

$$R_i = [r_{i,1}, r_{i,a}, \dots, r_{i,A}] \quad (14)$$

また、アイテム  $i$  における評価軸  $a$  の極性の割合  $r_{i,a}$  は、評価軸  $a$  を構成する属性語と係り受け関係にある肯定評価表現の総数  $P_{i,a}$  と否定評価表現の総数  $N_{i,a}$  を用いて式(15)で定義される。

$$r_{i,a} = \frac{P_{i,a}}{P_{i,a} + N_{i,a}} \quad (15)$$

### 3.4 評価値の予測

評価軸を用いたアイテム  $i_m, i_b$  の類似度  $S_a(i_m, i_b)$  は式(14)で定義したアイテムの特徴ベクトルのコサイン類似度により算出される。

評価値の予測では、図 5 に示すように 2 種類のアイテムの特徴ベクトルを用いる。本稿では、特徴ベクトルの類似度の扱いに応じて、2 種類の予測手法を提案する。

#### 3.4.1 提案手法 1

提案手法 1 で用いるアイテム  $i_m, i_b$  の類似度  $S_p(i_m, i_b)$  は、式(16)で定義される。

$$S_p(i_m, i_b) = S_t(i_m, i_b) + S_a(i_m, i_b) \quad (16)$$

また、図 6 に示すように、提案手法 1 の予測評価値は式(16)の類似度を用いて、式(17)で定義される。

$$x_{p1} = \bar{u}_k + \frac{\sum_b S_p(i_m, i_b)(x_{k,b} - \bar{u}_k)}{\sum_b |S_t(i_m, i_b)| + \sum_b |S_a(i_m, i_b)|} \quad (17)$$

#### 3.4.2 提案手法 2

提案手法 2 では、まず LDA を用いたアイテムの特徴ベクトルの類似度  $S_t(i_m, i_b)$  を用いて、最近傍の評価値を発見する。そして、最近傍の評価値にのみ評価軸を用いた類似度  $S_a(i_m, i_b)$  を合算し、評価値の予測に利用する。

使用する類似度と予測評価値は式(16), (17)と同様であるが、図 7 に示すように、最近傍の評価値にのみ  $S_a(i_m, i_b)$  を合算する部分が提案手法 1 と異なる。

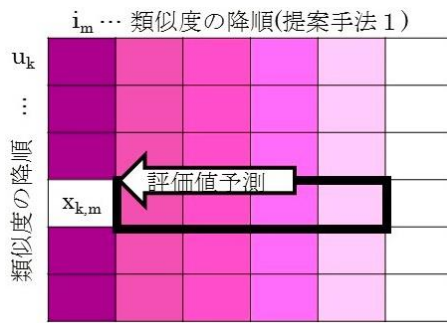


図6 提案手法1の評価値予測




図7 提案手法2の評価値予測

#### 4. 評価実験

評価値予測のタスクにおいて、3章で述べた提案手法と2章で述べたベースラインならびに評価軸情報のみを用いた手法と岡田らのtf-idf法を用いた手法を比較する。

##### 4.1 実験データ

本実験では、2つのWebサイトからデータを収集した。まずは、Amazonから評価値行列を構築するためのデータを<ユーザ, 書籍, 評価値>の3つ組で収集した。このとき、評価値行列が疎であると手法を正確に評価することができないため、20冊以上の書籍を評価しているユーザを評価対象とした。該当するユーザ数は4,010人であり、該当ユーザが評価した書籍の種類数は30,779冊であった。

次に、このデータをテスト用と訓練用の2種類のデータに分けた。テストデータは、4,010人からランダムに抽出された100人のユーザによって構成される。これより、テストデータは100×30,779の評価値行列で表現され、訓練用のデータは3,910×30,779の評価値行列で表現される。

また、書籍のレビューテキストは読書メーターから収集した。読書メーターとは、レビュー投稿型のWebサイトである。Amazonの書籍のレビュー数よりも読書メーターの書籍のレビュー数が多いため、読書メーターを利用した。読書メーターから取得したレビュー件数は5,688,553件であり、レビュー文数は21,519,574文であった。

##### 4.2 実験内容

4.1の100人のテストデータに対し、訓練データを用いて評価値の予測を行う。この際に、テストデータと訓練デ

ータには5分割交差検定を行う。

評価値予測タスクの評価指標はMSE(平均二乗誤差)を用いる。予測対象の評価値を $x_{k,m}$ 、予測評価値を $\hat{x}_{k,m}$ とすると、MSEは式(18)で定義される。

$$MSE = \frac{\sum_{k=1}^N (x_{k,m} - \hat{x}_{k,m})^2}{N} \quad (18)$$

$N$ は評価するデータ数であり、本実験で予測するテストデータの数は100件であるので、 $N$ の値は100である。

#### 5. 実験結果及び考察

表4に実験結果を示す。本実験では評価軸の数によって提案手法と評価軸のみを用いる手法の予測精度が変わるので、これらの手法は平均値を表4に示す。

表4より、提案手法2のMSEが全手法のなかで最も低い値となり、提案手法2が最も予測誤差の少ない手法であることが示された。次に、MSEが低いのはトピックアイテムベースの手法であり、予測精度の最も悪かった手法はユーザベースの手法となった。提案手法2はベースラインと比較して、MSEにおいて最大で0.133ポイント向上し、有効性を確認できた。

また、図8に評価軸の数と各手法のMSEの関係を示す。提案手法2では評価軸の数が10から15の間で精度の良い結果となった。加えて、評価軸の数も変化しても、全てのベースラインより提案手法2の予測評価値が優れていることが確認できた。

提案手法2では、トピック分布が類似するアイテムの最近傍の評価値にのみ評価軸の類似度を合算している。これより、評価値予測のタスクにおいては「書籍の内容が似ている、そのうえで評価軸が類似している」アイテム間では評価傾向が強く類似すると考えられる。

一方で、提案手法1と評価軸のみを用いた手法では、予測評価値のばらつきが大きく、ほとんどの結果でユーザベース以外のベースラインよりも精度が低くなった。これより、評価軸の類似度が大きく影響するようにアイテム間の類似度を設定することは、書籍の評価値予測のタスクにおいて有効でないと考えられる。

表4 提案手法とベースラインのMSE

手法	MSE
ユーザベース	0.846
アイテムベース	0.782
岡田らの手法(tf-idf)	0.794
トピックアイテムベース	0.732
評価軸のみ	0.843
提案手法1	0.795
提案手法2	0.713

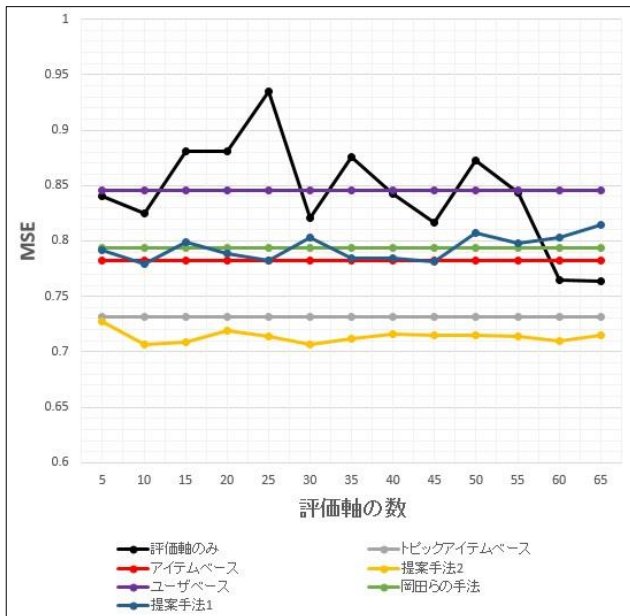


図 8 評価軸の数と各手法の MSE

提案手法 2 におけるエラー分析を行った結果、2 種類の原因が考えられた。1 つ目の原因は、予測評価値の近傍に評価値が存在しないため、ユーザの平均評価値が予測評価値となり、精度が下がるという原因である。2 つ目の原因は、ユーザの主観を考慮していないため精度が下がるという原因である。提案手法では、予測対象の書籍を大多数のレビュアーが「文章が読みやすい書籍」と評価すると、最近傍には同じように大多数のレビュアーが読みやすいと評価する書籍が表れる。しかし、ユーザ毎に主観は異なるため、予測対象のユーザが予測対象の書籍に対して少数側の評価をする場合、今回の手法では予測の精度が下がってしまう。これらの原因に対処するには、ユーザの特徴ベクトルにトピック情報や評価軸情報を適用して、ユーザの嗜好に関する最適な素性を選択することが対策として考えられる。

## 6. おわりに

本稿では、書籍レビューテキストから生成した評価軸とトピックモデルを用いたハイブリッド型推薦手法を提案した。評価実験では、トピック分布が類似するアイテムの最近傍の評価値にのみ評価軸の類似度を合算する提案手法 2 が最も精度が高く、ベースラインと比較して最大で 0.133 ポイントの向上を確認できた。実験結果より、評価値タスクにおける提案手法の有効性を確認できた。

今後の課題としては、ユーザの特徴ベクトルを作成においてトピック情報と評価軸情報を適用することが考えられる。その際には、ユーザの嗜好を表現するうえで有効な素性について検討したいと考えている。また、書籍以外の商品カテゴリでの有効性の実証を試みたいと考えている。本稿では、提案手法の有効性を確認するために、精度の高い

辞書を作成する必要があった。そのため一部の処理を人手で行っており、他の全てのカテゴリで同様の処理をすることはコストが高いと考えられる。精度の高い属性語辞書と評価表現辞書の自動が作成できることにより、他の商品カテゴリでも利用できる汎用性の高い手法が実現可能になると考えられる。最終的には、手法の自動化を実現した後に、家電や映画、音楽といった他の商品カテゴリでも提案手法の有効性を検討する予定である。

## 参考文献

- [1] Konstan, J. A. and Riedl, J.: Recommender system: Collaborating in commerce and communities. In Proc. of the SIGCHI Conf. on Human Factors in Computing System, 2003.
- [2] Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., and Riedl, J.: GroupLens: an open architecture for collaborative filtering of netnews, In Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work, pp.175-186, 1994.
- [3] Wang, J., De Vries, A. P., and Reinders, M. J.: Unifying user-based and item-based collaborative filtering approaches by similarity fusion, In Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, pp.501-508, 2006.
- [4] 岡田瑞穂, 藤井敦. レビューテキスト間の類似度を用いた協調フィルタリング, 言語処理学会第 18 回年次大会, Vol.3, pp.1-4, 2012.
- [5] Blei, D. M., Ng, A. Y., and Jordan, M. I.: Latent Dirichlet Allocation, The Journal of Machine Learning Research, Vol.3, No.5, pp.993-1022, 2003.
- [6] 北原将平, ジェブカ ラファウ, 荒木健治. レビューテキストを対象としたハイブリッド型推薦手法におけるトピックモデルの有効性について, Proceedings of the 30th Annual Conference of the Japanese Society for Artificial Intelligence, 1K4-OS-06a-4in1, 2016.
- [7] Ganu, G., Elhadad, N., and Marian, A.: Beyond the Stars Improving Rating Predictions using Review Text Content, Web and Databases, Vol.9, pp.1-6, 2009.
- [8] グェン ファム タン タオ, 岡部誠, 尾内理紀夫, 林孝宏, 西岡悠平, 竹中孝真, 森正弥. 新たな弱教師付き型分類手法 Bautext, 情報処理学会論文誌, Vol. 52, No.1, pp.269-283, 2011.
- [9] 金兵裕太, 沼尾雅之. ネットショッピングサイトの商品レビューを利用したジャンル毎の評価軸の自動構築, 第 14 回日本データベース学会年次大会, C2-3, 2016.
- [10] Kudo, T., Yamamoto, K., Matsumoto, Y.: Applying Conditional Random Fields to Japanese Morphological Analysis, Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing, pp.230-237, 2004.
- [11] Kudo, T. and Matsumoto, Y.: Japanese dependency analysis using cascaded chunking. Proceeding of the 6th conference on Natural Language Learning-Volume 20. Association for Computational Linguistics, pp.63-69, 2002.
- [12] “日本語 WordNet”. <http://nlpwww.nict.go.jp/wn-ja/>, (参照 2016/12/14)
- [13] 小林のぞみ, 乾健太郎, 松本裕治, 立石健二, 福島俊一. 意見抽出のための評価表現の収集. 自然言語処理, Vol.12, No.3, pp.203-222, 2005.
- [14] 東山昌彦, 乾健太郎, 松本裕治. 述語の選択嗜好性に着目した名詞評価極性の獲得, 言語処理学会第 14 回年次大会論文集, pp.584-587, 2008.