

## 類似アイテムを用いたコールドスタートアイテムに対する説明可能なクロスドメイン推薦の性能向上

### Improving Performance of Explainable Cross-Domain Recommendations for Cold-Start Items Using Similar Items

福田 直人<sup>1)</sup> 山崎 禎晃<sup>2)</sup> 大原 剛三<sup>2)</sup>  
Naoto Fukuda Tomoaki Yamazaki Kouzou Ohara

#### 1 はじめに

推薦システムは、Electronic Commerce (EC) や Social Networking Service (SNS) において、ユーザが利用するアイテムやサービスを決定するための意思決定を支援する上で重要な役割を担っている。近年では、なぜそのアイテムが推薦されたのかをユーザに対して説明する、説明可能な推薦手法が研究されている [4]。また、推薦システムでは、過去の評価履歴が少ない新規のユーザやアイテムに対する推薦性能が低下するコールドスタート問題という普遍的な課題が知られており、疎なデータセットに対する推薦システムの頑健性を向上させることも重要視されている [7, 1]。推薦システムに対する信頼性、ユーザの満足度を向上させるとともに、疎なデータセットに対する頑健性の高い推薦システムを作成するためには、コールドスタート問題に対処しつつ、説明性を兼ね備えた推薦システムが必要である。

コールドスタート問題を解決する手法の 1 つに、異なるドメインのデータを用いて推薦を行うクロスドメイン推薦 [3] がある。具体的には、比較的データ数が多いドメインをソースドメイン、データ数が少ないドメインをターゲットドメインとし、ソースドメインの情報を活用してターゲットドメインにおけるアイテムの推薦性能を向上させる [6]。クロスドメイン推薦に説明性を加えた手法として、Cross-domain recommendation via Aspect Transfer Network (CATN) [5] が提案されている。CATN では、アイテムに付されたレビューからレビューを書いたユーザの嗜好とそのアイテムの特徴を表すアスペクトをそれぞれ抽出し、ユーザのアスペクトをソースドメインから転送してターゲットドメインのアスペクトとマッチングさせることでターゲットドメインにおけるコールドユーザの評価を予測している。CATN では、ドメイン間のアスペクトのつながりと各アスペクトに関する単語を可視化することによって説明可能な推薦も実現している。一方、アスペクトのマッチングにはターゲットドメインのアイテムに付けられたレビューが必要であるため、アイテムのコールドスタート問題には対応不可能である。

そこで本研究では、CATN におけるアイテムのコールドスタート問題を解決することで、ユーザとアイテムの両方のコールドスタート問題に対応する説明可能なクロスドメイン推薦の実現を目指す。具体的には、コールドスタートアイテムに対して仮想的な評価値を生成し、推薦対象のアイテムと評価傾向が類似するアイテムを獲得する。それらの類似アイテムのレビューからアスペクトを抽出し、推薦対象のアイテムのアスペクトとして利用することで、既存手法の説明性を維持しつつ、推薦性能

- 1) 青山学院大学大学院理工学研究科
- 2) 青山学院大学理工学部

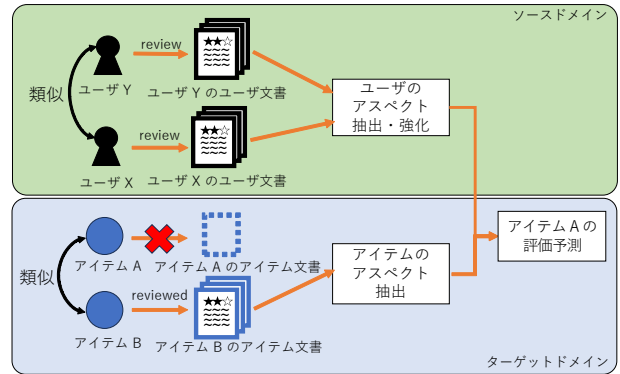


図 1: 提案手法の概要図

の向上を図る。評価実験では、実際のデータセットを用いて提案手法の推薦性能を定量的に評価し、既存手法と比較してコールドスタートアイテムに対する推薦性能を改善できることを確認し、同時に説明性能も維持できていることを定性的に確認する。

#### 2 提案手法

提案手法は、CATN [5] を基盤とし、ターゲットドメインにおけるコールドスタートアイテムの評価予測のために、そのアイテムと類似するアイテムからアスペクトを獲得する機構を CATN に追加したものである。図 1 に提案手法の概要を示す。図中のユーザ文書はそのユーザが書いたレビューをまとめたものであり、アイテム文書はそのアイテムに付されたレビューをまとめたものである。CATN は、ソースドメインからユーザのアスペクトを抽出、ターゲットドメインから獲得したアイテムのアスペクトとのマッチングに基づいて評価を予測する。また、推薦対象ユーザ X のユーザアスペクトは、X と同じアイテムに同評価を付けるユーザ Y のアスペクトで強化される。これに対し提案手法では、評価値とレビューがない推薦対象アイテム A に関しては、まず仮想的な評価値を生成し、生成した仮想評価値に基づいて非コールドな類似アイテム B を選定し、B のレビューから得たアスペクトで評価予測を行う。

##### 2.1 CATN におけるアスペクトベースの評価予測

###### 2.1.1 アスペクト抽出

CATN では、各ドメイン内におけるユーザ  $u$  のレビューをまとめたユーザ文書  $\mathbf{D}_u = [w_1, w_2, \dots, w_l]$  からユーザのアスペクトを獲得する。ここで、 $w_j$  はユーザ  $u$  のレビュー中の単語、 $l$  は文書長である。具体的には、各単語を埋め込み表現に射影した行列に畳み込み処理を適用することで、単語  $w_j$  の潜在的な文脈特徴を表す  $n$  次元ベクトル  $\mathbf{c}_{j,u} \in \mathbb{R}^n$  から構成される特徴行列  $\mathbf{C}_u = [\mathbf{c}_{1,u}, \mathbf{c}_{2,u}, \dots, \mathbf{c}_{l,u}]$  を獲得し、次式に従って  $m$  番

目のアスペクトに対する単語  $w_j$  のアスペクト固有特徴  $\mathbf{g}_{m,j,u}$  を獲得する.

$$\mathbf{g}_{m,j,u} = (\mathbf{W}_m \mathbf{c}_{j,u} + \mathbf{b}_m) \odot \sigma(\mathbf{W}_m^g \mathbf{c}_{j,u} + \mathbf{b}_m^g) \quad (1)$$

ここで,  $\sigma$  はシグモイド活性化関数,  $\odot$  は要素積を表す演算子,  $\mathbf{W}_m, \mathbf{W}_m^g \in \mathbb{R}^{k \times n}$  と  $\mathbf{b}_m, \mathbf{b}_m^g \in \mathbb{R}^k$  は  $m$  番目のアスペクトの変換行列とバイアスペクトル,  $k$  はアスペクト表現の潜在的な次元である. 獲得した  $\mathbf{g}_{m,j,u}$  から次式を用いて  $m$  番目のアスペクト表現  $\mathbf{a}_{m,u}$  を獲得する.

$$\mathbf{a}_{m,u} = \sum_{j=1}^l \beta_{m,j,u} \mathbf{g}_{m,j,u} \quad (2)$$

$$\beta_{m,j,u} = \frac{\exp(\mathbf{g}_{m,j,u}^T \mathbf{v}_{m,s})}{\sum_{i=1}^l \exp(\mathbf{g}_{m,i,u}^T \mathbf{v}_{m,s})} \quad (3)$$

ここで,  $\beta_{m,j,u}$  は  $m$  番目のアスペクトに対する単語  $w_j$  の重要度,  $\mathbf{V}_s = [\mathbf{v}_{1,s}, \dots, \mathbf{v}_{M,s}]$ ,  $\mathbf{V}_t = [\mathbf{v}_{1,t}, \dots, \mathbf{v}_{M,t}]$  はドメインごとの重要なアスペクトを示すグローバルアスペクト表現である. これにより,  $M$  個のアスペクト表現から構成されるアスペクト行列  $\mathbf{A}_u = [\mathbf{a}_{1,u}, \dots, \mathbf{a}_{M,u}]$  を獲得できる. アイテムのレビュー文をまとめたアイテム文書  $\mathbf{D}_i$  に対しても, 同様に  $\mathbf{A}_i$  を獲得する.

### 2.1.2 ユーザアスペクトの強化

ユーザ  $u$  のユーザアスペクト  $\mathbf{A}_u$  は,  $u$  と同じアイテムに対して同じ評価を付けるユーザによって書かれた補助レビュー文書  $\mathbf{D}_{u_{aux}}$  から得られる補助ユーザの特徴行列  $\mathbf{C}_{u_{aux}}$  を用いて強化される. 具体的には,  $\mathbf{C}_{u_{aux}}$  を用いて補助ユーザのユーザアスペクト  $\mathbf{A}_{u_{aux}}$  を獲得し, 次式を用いて  $\mathbf{A}_u$  を強化する.

$$\mathbf{A}_u = \tanh(\mathbf{W}_f^2 [\mathbf{A}_u \oplus (\mathbf{g}_{aux} \odot \mathbf{A}_{u_{aux}})] + \mathbf{b}_f^2) \quad (4)$$

$$\mathbf{g}_{aux} = \sigma(\mathbf{W}_f^1 [(\mathbf{A}_u - \mathbf{A}_{u_{aux}}) \oplus (\mathbf{A}_u \odot \mathbf{A}_{u_{aux}})] + \mathbf{b}_f^1) \quad (5)$$

ここで,  $\oplus$  は連結演算子,  $\mathbf{W}_f^1, \mathbf{W}_f^2 \in \mathbb{R}^{k \times 2k}$  は変換行列,  $\mathbf{b}_f^1, \mathbf{b}_f^2 \in \mathbb{R}^k$  はバイアスペクトルである.

### 2.1.3 アスペクトマッチングによる評価予測

最終的なユーザ  $u$  のアイテム  $i$  に対する予測評価値  $\hat{r}_{u,i}$  は, ドメイン間での重要なアスペクトのペアを強調するグローバルクロスドメインアスペクト相関行列  $\mathbf{S}$ , ユーザ  $u$  とアイテム  $i$  のアスペクト特徴  $\mathbf{A}_u, \mathbf{A}_i$  の各アスペクトペア間のマッチング度  $\mathbf{S}_{u,i}$  を用いて以下のように計算する.

$$\hat{r}_{u,i} = \frac{1}{M * M} \sum_{p=1}^M \sum_{q=1}^M \mathbf{S}_{u,i}^r(p, q) + b_u + b_i \quad (6)$$

$$\mathbf{S}_{u,i}^r = \mathbf{S} \odot \mathbf{S}_{u,i} \quad (7)$$

$$\mathbf{S}_{u,i} = \mathbf{A}_u^T \mathbf{W}_a \mathbf{A}_i \quad (8)$$

$$\mathbf{S} = \text{LeakyReLU}(\mathbf{V}_s^T \mathbf{W}_v \mathbf{V}_t) \quad (9)$$

ここで,  $\mathbf{W} \in \mathbb{R}^{k \times k}$  は学習可能な変換行列,  $b_u, b_i$  はそれぞれ, ユーザとアイテムに対するバイアスである.

## 2.2 仮想評価値による類似アイテムの決定

提案する仮想的な評価値を用いた類似アイテムの決定プロセスを図 2 に示す. ここでは, すべてのアイテム




図 2: 類似アイテム決定のプロセス

の説明文に対して, Tsai らの手法 [2] と同様の前処理を実施し, 意味のある  $d$  個の単語の集合  $\mathbf{T} = \{t_1, t_2, \dots, t_d\}$  を獲得する. 次に, 各説明文における各単語の出現頻度を計算することで, アイテム  $i$  のコンテンツ特徴  $\mathbf{y}_i = [y_{i,1}, y_{i,2}, \dots, y_{i,d}]$  を獲得する. このアイテムのコンテンツ特徴を用いてアイテム間の類似度を計算し, 獲得した類似度を基にコールドスタートアイテム  $j$  の仮想的な評価値を次のように定義する.

$$\hat{r}_{u,j} = \frac{\sum_{i \in I^\alpha(u,j)} r_{u,i} R_{i,j}}{\sum_{i \in I^\alpha(u,j)} R_{i,j}} \quad (10)$$

ここで,  $R_{i,j}$  はアイテム  $i, j$  間の類似度を表すピアソンの相関係数,  $r_{u,i}$  は非コールドスタートアイテム  $i$  に対するユーザ  $u$  の実際的评价値,  $I_{u,j}^\alpha$  はコールドスタートアイテム  $j$  と最も類似する  $\alpha$  個のユーザ  $u$  に評価された非コールドスタートアイテムの集合である. 生成された仮想評価値は, そのアイテムに対するユーザ  $u$  からの評価と解釈することができるため, そのユーザがその仮想評価値と最も近い評価をしたアイテムを選択することによって, 最終的な類似アイテムを決定する.

## 3 評価実験

### 3.1 データセット

本実験では, CATN [5] における実験と同様に, Amazon product data<sup>1</sup> から, Books (以下, Book ドメイン), Movies and TV (以下, Movie ドメイン) の 2 カテゴリを選択し, 各カテゴリ内で 5 件以上のレビューを持つユーザ-アイテムのインタラクションに関するデータである 5-core データセットを利用した. 各 5-core データセットに対して, レビューテキストのないレコード, インタラクション数が 10 未満のユーザおよび 30 未満のアイテムに関するレコードを削除した. また, ターゲットドメインとして利用する Movie ドメインに関しては, 各カテゴリ内のアイテムの説明文の情報を持つ metadata データセットも獲得した. データの分割方法についても CATN [5] に従い, ソースドメインとターゲットドメインの両方に存在するユーザ (以下, 重複ユーザ) のうち, 50% をモデルの訓練用のユーザとし, 残りの 50% をモデルがインタラクションを確認不可能なコールドスタートユーザとした. さらに, 後者のうちの 40% を検証用ユーザ, 60% をテスト用ユーザとした.

### 3.2 各テキストデータに対する前処理

5-core データセットの各レビュー文に関しては, CATN [5] に従い, ストップワード, 相対文書頻度が 0.5 以上の単語, **tf-idf** スコアが上位 20,000 語以外の単語を除去した. 次に各単語に 0 から始まる単語 ID を割り当て, 各レビュー文を単語 ID 列に変換し, 長さを 500 に統一した. また, 各単語の初期埋め込みベクトルを獲得

1) <https://cseweb.ucsd.edu/~jmcauley/datasets/amazon/links.html>

表 1: CATN と提案手法の MSE

$\eta_{user}(\%)$		100		50	
$\eta_{item}(\%)$	手法	CATN	提案手法	CATN	提案手法
	10		2.662	1.089	2.717
20		4.335	1.130	4.388	1.137
30		5.929	1.141	6.069	1.159
40		7.488	1.168	7.588	1.186
50		9.032	1.203	9.160	1.205

するために, Google News<sup>2)</sup>の事前学習済単語埋め込みを利用した. 各 metadata データセット中の各アイテムの説明文に対する前処理は, Tsai ら [2] の設定を参考にした. 具体的には, アイテムの説明文からアイテムのコンテンツ特徴として有用な単語の集合を獲得し, 説明文間の類似度計算の時間短縮のために, カテゴリ内のすべての説明文中における単語の出現頻度が上位 10,000 語以外の単語を除去した.

### 3.3 パラメータ設定

本実験では, 複数ドメインに存在するユーザは通常少ないことを考慮し, 訓練に利用する重複ユーザの割合  $\eta_{user}(\%)$  には 50% と 100% の 2 種類を用いた. さらに, ターゲットドメインのコールドスタートアイテムの割合  $\eta_{item}(\%)$  を  $\eta_{item} \in \{10, 20, 30, 40, 50\}$  とし, 異なるコールドスタートアイテム状況下における推薦性能を確認した. また Tsai ら [2] の研究から, 仮想評価値生成に利用するアイテム数  $\alpha$  が大きいほど, 仮想評価値の精度が高くなるということが分かっている. このことから,  $\alpha \in \{30, 40, 50\}$  とし, 提案手法への影響を調査した. その他のパラメータ設定は, CATN [5] と同じ値を利用し, アスペクト表現数は  $M = 3$  とした.

### 3.4 推薦性能の定量評価

CATN と提案手法の推薦性能を, 推薦アイテムの評価値に対する Mean Squared Error (MSE) を用いて評価した. その結果を表 1 に示す. この結果から, すべての実験設定において, CATN よりも提案手法の方が MSE が低く, 推薦性能が高いことがわかる. また, コールドスタートアイテムの割合  $\eta_{item}$  を大きくした場合の MSE を比較すると, 提案手法の方が性能低下の割合が小さく, コールドスタートアイテムが多い場合でも, 提案手法は推薦性能に影響を受けにくいことがわかる.

次に, CATN と提案手法の性能差の要因を考察するために, 訓練データにおける評価回数ごとに計算した推薦アイテムの評価値に対する MSE を調べた. 仮想評価値生成に利用するアイテム数  $\alpha = 50$ , 訓練に利用する重複ユーザの割合  $\eta_{user}(\%) = 50$ , ターゲットドメインのコールドスタートアイテムの割合  $\eta_{item}(\%) = 10$  の場合の結果を図 3 に示す. この結果から, 評価回数 0 回のアイテムに関しては, CATN の MSE が非常に高いのに対して, 提案手法の MSE は 1.350 と低く, 評価回数が 1 回以上の場合, 両者の MSE は同程度であることがわかる. このことから, 提案手法は CATN が対応できない評価回数が 0 回の完全なコールドスタートアイテムに対して有効な手法であると考えられる.




図 3: 訓練データ中のアイテムの評価回数が 0 回から 50 回のアイテムに対する MSE

表 2: グローバルクロスドメインアスペクト相関行列  $\mathbf{S}$ 

		アイテムアスペクト (ターゲットドメイン)		
		1	2	3
ユーザアスペクト (ソースドメイン)	1	0.304	0.248	0.262
	2	0.367	-0.001	0.344
	3	-0.006	<b>0.371</b>	-0.026

### 3.5 説明性分析

CATN での説明性が提案手法でも維持できているかを確認するために, CATN での説明性分析方法に従って提案手法の説明性を分析した. まず, アスペクト転送の重要度を表すグローバルクロスドメインアスペクト相関行列  $\mathbf{S}$  から, ユーザとコールドスタートアイテムのアスペクトのペアのうち重要度が最も高いペア  $(i, j)$  を確認し,  $i$  番目のユーザアスペクト,  $j$  番目のアイテムアスペクトそれぞれに関連する上位 10 単語  $Asp_u[i]$ ,  $Asp_v[j]$  を獲得した. そして,  $Asp_u[i]$ ,  $Asp_v[j]$ , ソースドメインにおけるユーザ文書  $D_{s_u}$ , ターゲットドメインにおけるアイテム文書  $D_{t_v}$ , ユーザ  $u$  がアイテム  $v$  に実際に書いたレビュー  $D_{t_{u,v}}$  を用いて, 獲得した上位単語と, そのユーザおよびアイテムが持つレビューの関連性を調べた. ここでは, 仮想評価値生成に利用するアイテム数  $\alpha = 50$ , 訓練に利用する重複ユーザの割合  $\eta_{user}(\%) = 50$ , ターゲットドメインのコールドスタートアイテムの割合  $\eta_{item}(\%) = 20$  という設定の下でランダムに選択した 2 つのユーザ-コールドスタートアイテムのペアにおける推薦結果を分析対象とした.

まず, 上記の設定下における行列  $\mathbf{S}$  を表 2 に示す. 表 2 より, 上記の設定下における最も重要なアスペクトのペアはユーザの第 3 アスペクト-アイテムの第 2 アスペクトであることが分かる. そのため, ランダムに選択したユーザ-コールドスタートアイテムの 2 つの推薦例における  $Asp_u[3]$ ,  $Asp_v[2]$ ,  $D_{s_u}$ ,  $D_{t_v}$ ,  $D_{t_{u,v}}$  を表 3 に示す. まず, 例 1 に着目する.  $D_{s_u}$  より, このユーザの嗜好が 'complicated' であることがわかる. これは,  $Asp_u[3]$  で示される, ユーザのアスペクトに関連する重要な単語と一致している. よって, ユーザのアスペクトがこのユーザの嗜好を正しく表現できていると考えられる. また,  $D_{t_v}$  はこのアイテムに対して実際に付けられたレビューであるため, このアイテムが持つ嗜好は 'editing' であることがわかる.  $Asp_v[2]$  はこのアイテムのレビューから直接抽出したアスペクトではないが, アスペクトに関連する単語として, このアイテムが実際に持つ嗜好と同じ 'editing' を上げている. さらに,  $D_{t_{u,v}}$  より, このユーザはこのアイテムの 'editing' を実際に評価

2) <https://code.google.com/archive/p/word2vec/>

表 3: 2 つの推薦例に対する説明性の分析

例 1 (uid: 5511, iid: 817, $r_{u,v} = 4.0$ , $\hat{r}_{u,v} = 4.23$ )	
$Asp_u[3]$	'complicated', 'too', 'boring', 'typical', 'fighting', 'among', 'view', 'gentleman', 'terrific', 'startled'
$Asp_v[2]$	'shaky', 'could', 'steeped', 'wait', 'lovely', 'guest', 'good', 'behind', 'madcap', 'editing'
$D_{s_u}$	But though seemingly ' <b>complicated</b> ', Zahn's expertise is put to use as he deftly weaves a tale with numerous 'threads' yet makes up one intricately woven 'tapestry'. (5.0)
$D_{t_u}$	Film <b>editing</b> in charge of Peter Boyle is very good. (5.0)
$D_{t_{u,v}}$	... terrific camera work, a pretty sound plot, and nice <b>editing</b>
例 2 (uid: 42203, iid: 10359, $r_{u,v} = 3.0$ , $\hat{r}_{u,v} = 4.23$ )	
$Asp_u[3]$	'over', 'trace', 'vaguely', 'ideas', 'malicious', 'possible', 'characters', 'epic', 'explain', 'historical'
$Asp_v[2]$	'settle', 'suspense', 'violent', 'differs', 'then', 'recommend', 'dirty', 'river', 'look', 'bring'
$D_{s_u}$	The last oracle is simply a great read; you'll find the <b>characters</b> and ideas stay with you long after ... (5.0)
$D_{t_u}$	... she was equally funny and <b>then</b> in reruns ... (5.0)
$D_{t_{u,v}}$	該当なし



しているため、嗜好が正しく転送されていることを確認できる。類似アイテムが持つ嗜好が、このアイテムの嗜好と類似していたことによって、レビューのないコールドスタートアイテムにおいても、説明性を維持できたと考えられる。次に、例 2 に着目すると、 $D_{t_u}$  と、類似アイテムから獲得したアスペクトに関連する単語  $Asp_v[2]$  で一致するものは、'then' など嗜好情報に直接関連しないものしか確認できなかった。このことから、レビュー文に対する前処理が十分ではなかったことが考えられる。また、最終的な評価予測  $\hat{r}_{u,v}$  と実際の評価値  $r_{u,v}$  も、例 1 と比較して大きく離れていることがわかる。この原因として、アスペクトを抽出した類似アイテムの嗜好と、評価予測を行うアイテム  $v$  の嗜好が類似しなかったことが考えられる。これらのことから、類似アイテムの選択方法は、提案手法におけるコールドスタートアイテム推薦において、推薦性能および説明性に対して、大きな影響を与えると考えられる。

### 3.6 $\alpha$ の大きさによる影響の分析

前述のように、仮想評価値生成に利用するアイテム数  $\alpha$  の増加にともない、仮想評価値の MSE が低下することから、 $\alpha$  が大きくなるほど提案手法における推薦精度も向上することが期待できる。この点を確認するために、異なる  $\eta_{user}$ ,  $\eta_{item}$  の下で、 $\alpha$  の値を 30, 40, 50 と変化させた場合の提案手法の推薦精度 (MSE) を調べた。その結果を図 4 に示す。結果として、すべての実験設定において、 $\alpha$  の増加による提案手法の MSE の単調な低下は確認できなかった。むしろ、 $\eta_{user}(\%) = 100$  における  $\alpha = 40$  と  $\alpha = 50$  の MSE の値を比較すると、 $\alpha = 50$  で大きく増加していることが確認できる。これらの結果、および、前節の結果を踏まえると、仮想評価値の精度が高くなったとしても、利用する類似アイテムのアスペクトが推薦精度に与える影響の方が大きいものと考えられる。

## 4 おわりに

本研究では、アスペクトに基づいた説明可能なクロスドメイン推薦手法である CATN に対して、コールドス

(a)  $\eta_{user}(\%) = 50$ (b)  $\eta_{user}(\%) = 100$ 図 4:  $\alpha$  を変更した際の提案手法の MSE

タートアイテムの推薦性能を向上させる手法を提案した。提案手法では、コールドスタートアイテムに対して仮想評価値を計算し、それに基づく類似アイテムのアスペクトを利用することで、従来の CATN の枠組みのままコールドスタートアイテムに対する推薦性能の向上を実現した。また、評価実験では、提案手法が CATN と同様の説明性をもち得ることを定性的に確認した。今後、複数の類似アイテムのアスペクトを合成して利用することで、単一の類似アイテムのアスペクトに大きく依存し得る推薦性能を安定化させる必要がある。

### 参考文献

- [1] Schein, A. I., Popescul, A., Ungar, H., and Pennock, M. Methods and metrics for cold-start recommendations. In *Proc. of SIGIR 2002*, pages 253–260, 2002.
- [2] Tsai, C.-Y., Chiu, Y.-F., and Chen, Y.-J. A Two-Stage Neural Network-Based Cold Start Item Recommender. *Applied Sciences*, 11(9):4243, 2021.
- [3] Zang, T., Zhu, Y., Liu, H., Zhang, R., and Yu, J. A Survey on Cross-domain Recommendation: Taxonomies, Methods, and Future Directions. *ACM Transactions on Information Systems*, 41(2), 2022.
- [4] Zhang, Y., and Chen, X. Explainable Recommendation: A Survey and New Perspectives. *Foundations and Trends in Information Retrieval*, 14(1):1–101, 2020.
- [5] Zhao, C., Li, C., Xiao, R., Deng, H., and Sun, A. CATN: Cross-Domain Recommendation for Cold-Start Users via Aspect Transfer Network. In *Proc. of SIGIR 2020*, pages 229–238, 2020.
- [6] Zhu, F., Wang, Y., Chen, C., Zhou, J., Li, L., and Liu, G. Cross-Domain Recommendation: Challenges, Progress, and Prospects. In *Proc. of IJCAI '21*, pages 4721–4728, 2021.
- [7] 風間 正弘, 飯塚 洗二郎, 松村 優也. 推薦システム実践入門: 仕事でつかえる導入ガイド. オライリージャパン, 2022.