

繰り返し消費されるコンテンツを対象とした推薦理由の提示

佃 洗撰^{1,a)} 後藤 真孝^{1,b)}

概要：ユーザにコンテンツを推薦する際に適切な推薦理由を提示することは、推薦システムの説得力や満足度を向上させるうえで重要な役割を果たす。既存研究ではユーザにとって未知のコンテンツを推薦するための推薦理由の提示に焦点が当てられてきたが、楽曲の聴取や飲食店の訪問などのドメインでは、ユーザは同じコンテンツ（楽曲や飲食店）を繰り返し消費することが多い。そこで本稿では、繰り返し消費されるコンテンツを対象とした推薦理由の提示という概念を提唱する。楽曲の聴取では繰り返し消費されるコンテンツの割合が特に高いことが知られているため、我々は楽曲推薦における9種類の推薦理由を、属人的要因、社会的要因、コンテンツ的要因の三つの要因に基づいて提案する。622人を対象としたアンケート調査を行い、9種類の推薦理由の有用性を検証し、さらに得られた知見の推薦への活用方法を議論する。

1. はじめに

推薦システムの説得力（コンテンツの消費や購入の促進度合い）や満足度（ユーザの推薦システムに対する満足度合い）を向上させるうえで、なぜ各コンテンツが推薦されたかをユーザが理解できるように推薦理由を提示することは、欠かすことのできない研究トピックのひとつとなっている [25]。こうしたアプローチは explainable recommendation (ER) と呼ばれる [29]。ERにおいて、ユーザに提示する推薦理由はそのユーザのコンテンツの消費履歴に基づいて生成されることが一般的である [28]。実験を通して、ERによってユーザがより正確にコンテンツを選択可能になること [5] やユーザがより多くの推薦コンテンツを消費すること [10] が報告されている。

推薦理由を生成するための様々なアプローチが提案されてきた [28] が、それらの大半はユーザにとって未知のコンテンツを推薦するための理由の提示に焦点を当てている。しかし、楽曲の聴取、動画の鑑賞、飲食店の訪問といったドメインでは、ユーザがしばしば同じコンテンツを繰り返し消費することが知られている [2], [4]。そのため、ユーザが既に消費したコンテンツを対象とした推薦理由の提示にも意義があると我々は考える。例えば、あるユーザが楽曲配信サービスで「Taylor Swift」の「Shake It Off」を初めて聴いてからちょうど5年が経過したとする。この場合、楽曲配信サービス上で「あなたが『Shake It Off』を初めて聴いてからちょうど5年が経過したので聴いてみませんか」

という理由とともに楽曲を推薦することもできる。ユーザが同一コンテンツを繰り返し消費する際、初めの頃は短い間隔で消費するが、ユーザがコンテンツに飽きるにつれて徐々に間隔が長くなり、最終的には消費しなくなるというのが典型的な振る舞いである [4]。しかし、繰り返し消費した結果としてユーザがある楽曲を聴かなくなったとしても、前述のような理由を提示することで、楽曲配信サービスはユーザがその楽曲を再度聴く可能性を高めることができる。さらに、ユーザはそのようにして推薦された楽曲を聴くことで、例えばその楽曲を頻繁に聴いていた当時のことを思い出して懐かしさを感じられるかもしれない。このような推薦は、ユーザが未知の楽曲だけでなく既知の楽曲を聴くことも促進するため、収益の面において楽曲配信プラットフォームにとっても有益である。こうした可能性があるにも関わらず、これまでの研究では繰り返し消費されるコンテンツを対象とした推薦理由の提示には取り組まれてこなかった。

以上のことを踏まえて本稿では、繰り返し消費されるコンテンツを対象とした推薦理由の提示に取り組む。消費済みのコンテンツに対する推薦理由を生成するために、我々は次の三つの要因を考慮する。

- **属人的要因**では、推薦対象となるユーザと、推薦されるコンテンツの間のインタラクションを考慮する。例えば、飲食店の訪問であれば「推薦されたレストランにあなたが初めて訪問してからちょうど7年が経過しました」といった理由が考えられる。
- **社会的要因**では、サービス上の全ユーザと、推薦されるコンテンツの間のインタラクションを考慮する。例

¹ 産業技術総合研究所

^{a)} k.tsukuda@aist.go.jp

^{b)} m.goto@aist.go.jp

例えば、動画の鑑賞であれば「推薦された動画を鑑賞したユニークユーザ数がちょうど10万人に到達しました」といった理由が考えられる。

- **コンテンツ的要因**では、ユーザとは無関係に決まる、コンテンツ固有の要素を考慮する。例えば、楽曲の聴取であれば「推薦された楽曲のアーティストが今日のライブでその楽曲を歌いました」といった理由が考えられる。

これらの要因に基づいて、我々は9種類の推薦理由を提案し、アンケート調査を通じてその有用性を検証する。

本研究の貢献を以下にまとめる。

- 繰り返し消費されるコンテンツを対象とした推薦理由の提示という概念を初めて提唱し、三つの要因（属人的要因，社会的要因，コンテンツ的要因）に基づいて9種類の推薦理由を提案した。
- 提案する推薦理由の有用性を検証するために、楽曲推薦を対象として、622人に対してアンケート調査を実施した。調査ではまず、9種類の各推薦理由の説得力を検証した。次に、8種類の推薦理由には経過時間や再生回数といった変数が含まれるため、変数がとる値と説得力の関係を検証した。
- 調査の結果、様々な知見が推薦理由の説得力（楽曲の人気度に関する推薦理由は説得力が高いなど）と変数の値と説得力の関係（いずれの推薦理由においても両者の関係には明確な傾向が存在するなど）の双方から得られた。また、得られた知見を、繰り返し消費されるコンテンツの推薦に活用する方法も提案した。

2. 関連研究

2.1 推薦理由の提示

これまでの研究で、推薦理由を提示することで推薦システムの説得力 [10] や満足度 [26] を向上できることが報告されている。推薦理由を提示するアプローチとして、ユーザ類似度やコンテンツ類似度といった情報源の中の一つを推薦理由として用いる方法がある。Herlocker ら [10]、Chang ら [7]、Symeonidis ら [24] の研究はこのアプローチに分類される。もう一つのアプローチは、複数の情報源を組み合わせることで推薦理由として用いるというものであり、前者のアプローチよりも有用であることが知られている [19]。後者のアプローチを扱う研究では、様々な情報源から得られる推薦理由の GUI を用いた可視化 [6], [11], [12], [18], [20], [27] に焦点が当てられることが多かったが、Kouki ら [16] の最近の研究で、GUI よりもテキストを用いた推薦理由の提示方法の方が説得力がより高くなることが明らかになった。Kouki らは HyPER [14] と呼ばれる、テキストに基づく推薦理由の生成フレームワークも提案している。

既存研究では推薦理由を提示する対象がユーザにとって未知のコンテンツであるのに対して、我々はユーザが繰り

返し消費して既知であるコンテンツを対象とする点に違いがある。上述の既存研究の知見に基づき、本稿では HyPER から生成されるテキストで記述された推薦理由を扱う。HyPER の概要は 3.1 節で述べる。

2.2 コンテンツの消費の繰り返し

推薦システムを扱う既存研究では、ユーザに対する未知のコンテンツの推薦を目的としてきた [1] が、様々なドメインにおいて同一ユーザが同じコンテンツを繰り返し消費することが知られている。例えば音楽の聴取と飲食店等の訪問ではそれぞれ、ユーザが消費するコンテンツの 69% と 51% が過去に消費したコンテンツであると報告されている [4]。こうした状況を反映して、コンテンツを繰り返し消費する行動のモデル化 [2], [4], [8] や過去に消費したコンテンツを再度推薦する手法の提案 [9], [13], [21], [22] が行われてきた。消費の繰り返しを分析することで、Benson ら [4] は各コンテンツにはユーザに固有の「寿命」があることを明らかにした。これはユーザがあるコンテンツを繰り返し消費する際、寿命の最初の頃はコンテンツが消費される間隔は短いが、寿命の最後の頃にはその間隔が長くなり、最終的にはユーザはそのコンテンツに飽きて消費しなくなる、というものである。繰り返し消費した結果ユーザに飽きられたコンテンツは、推薦の候補から除外されるのが一般的である。しかし、そのような飽きられたコンテンツであっても、適切な推薦理由とともに推薦すれば、ユーザは推薦結果を受け入れて再度そのコンテンツを消費するだろうと我々は考える。本研究は、ユーザが既に消費したコンテンツの再度の消費を促すうえで、どういった推薦理由であれば十分な説得力を持つかを明らかにするための第一歩となる研究である。

3. 繰り返し消費されるコンテンツを対象とした推薦理由

本章ではまず、HyPER フレームワーク [14] について説明し、我々が取り組む問題への適用方法を述べる。その後、繰り返し消費されるコンテンツに対する推薦理由を生成するために本稿で提案する三つの要因と、それに基づく9種類の推薦理由を述べる。

3.1 HyPER の概要

HyPER [14] は probabilistic soft logic (PSL) [3] を採用しており、「ルール」の集合によって推薦モデルを構築する。ルールの例として「ユーザ u が楽曲 s_1 を聴いたことがあり、 s_1 が楽曲 s_2 と類似していれば、 u は s_2 を聴くだろう」といったものがあげられる。HyPER では複数あるルールのうちどれを重視すべきかを自動的に学習し、ユーザが各コンテンツを推薦されたときに受け入れる確率を計算する。HyPER はさらにルールに対応する「スタイル」

表 1 9種類のスタイルと推薦理由の具体例.

要因	スタイル	次の理由で, Taylor Swift の Shake It Off をお勧めします:
属人的 要因	P-first	あなたが Shake It Off を初めて聴いてからちょうど 5年 が経過したからです.
	P-last	あなたが Shake It Off を最後に聴いてからちょうど 3年 が経過したからです.
	P-together	あなたが先程聴いた Lady Gaga の Applause と Shake It Off を過去に一緒によく聴いていたからです.
	P-total	次に Shake It Off を聴くと 100 回目の再生になるからです.
社会的 要因	S-total	Shake It Off の全ユーザの総再生回数が 100万 に到達したからです.
	S-unique	Shake It Off を聴いたユニークユーザ数が 10万 に到達したからです.
	S-favorite	Shake It Off をお気に入り登録したユーザ数が 1万 に到達したからです.
コンテンツ的 要因	I-release	Shake It Off がリリースされてからちょうど 5年 が経過したからです.
	I-live	今日のライブで Taylor Swift が Shake It Off を歌ったからです.

に基づいて推薦理由のテキストを生成する. 先程例にあげたルールであれば, 「楽曲 s_2 はあなたの好きな楽曲 s_1 と似ているため推薦します」というスタイルを用意して適用することで, 「楽曲『Shake it Off』はあなたの好きな楽曲『King of Anything』と似ているため推薦します」のような具体的な推薦理由のテキストが生成される. HyPER の特徴のひとつは拡張性の高さであり, どのような推薦理由であっても, それに対応するルールとスタイルを用意することでフレームワークに取り込むことができる. この利点を活かして次節では, 繰り返し消費されるコンテンツの推薦理由を生成するための9種類のルールとそれらに対応するスタイルを提案する.

3.2 推薦理由生成のためのルールとスタイル

本稿では, ユーザが既に消費したコンテンツが再度そのユーザに推薦される状況を想定する. 我々はそのような状況において, コンテンツが再度推薦された理由を提示することを目的とする. この目的を達成するために, 属人的要因, 社会的要因, コンテンツ的要因の三つの要因を考慮する. 楽曲の聴取においてはコンテンツの繰り返しの消費が特に顕著であるため [4], 本稿では楽曲推薦を対象とする. 表1に示すように, 本節では9種類のスタイルについて述べるが, これ以外のスタイルも考えられるかもしれない. しかし, ここでの我々の目的はあらゆるスタイルを網羅することではないことに注意されたい. そうではなく, 我々は三つの要因に基づいてスタイルの例を提示することを目的としている. それによって, どのようなサービスプラットフォームにおいても, サービス固有の特徴に応じた推薦理由を考える際に, 三つの要因がその礎になりうることを示せると考えている.

3.2.1 属人的要因

属人的要因では, 推薦対象となるユーザと推薦される楽曲の間のインタラクションを考慮する. ある楽曲配信サービス上でユーザが楽曲を聴取すると, サービス上には聴取のログが記録される. そのログを用いることで, 属人的要因に関する, P-first, P-last, P-together, P-total の4種類のスタイルを提案する. P-first および P-last はコンテ

ンツの消費日時に関する要因である. P-first のルールは「ユーザ u が楽曲配信サービス上で楽曲 s を初めて聴いてからちょうど x 年が経過したら, u は s を聴くだろう」であり, P-last のルールは「ユーザ u が楽曲配信サービス上で楽曲 s を最後に聴いてからちょうど x 年が経過したら, u は s を聴くだろう」である. ここで u は推薦対象のユーザであり, s は u により繰り返し消費された楽曲である. 表1の推薦理由の例では, 太字で記述された語はスタイルから生成される推薦理由中の変数の値であることを意味する. したがって, P-first の推薦理由で「5年」という値は「3年」「7年」「10年」といった値もとりのる. 各ユーザが自分の好みに応じて変数の値を設定できるようにするのが, 適切な値を決めるための方法のひとつである. あるいは, 楽曲配信サービスが全ユーザに共通の値を決めて設定するという方法も考えられる. 変数の値と推薦理由の説得力の関係については4.3章で検証する. P-together では, ユーザの楽曲再生履歴内での楽曲の共起 [23] に基づいて推薦理由が生成される. 楽曲 s' をユーザ u によって繰り返し消費されてきた楽曲とすると, ルールは「 u がたった今聴いた s' を過去に s と一緒に頻繁に聴いていたなら, u は s を聴くだろう」となる. P-first, P-last, P-together では, 推薦された楽曲を頻繁に聴いていた当時のことを思い出して懐かしさを感じられるため, これらの推薦理由には説得力があると仮定している. 最後に P-total ではユーザごとの楽曲再生回数を考慮し, 「 u が次に s を再生すると u による s の総再生回数が x に到達するならば, u は s を聴くだろう」というルールを持つ. この推薦理由では, 総再生回数を知ることによって「そんなにもたくさん聴いてきたのか」という達成感から説得力を感じると仮定している.

3.2.2 社会的要因

社会的要因では, サービス上の全ユーザと推薦されるコンテンツの間のインタラクションを考慮する. 社会的要因に関するスタイルとして, S-total, S-unique, S-favorite の3種類を提案する. S-total でのルールは「全ユーザによる s の総再生回数が x に到達したら, u は s を聴くだろう」であり, S-unique でのルールは「 s を再生したユニークユーザ数が x に到達したら, u は s を聴くだろう」である. 一

一般的な楽曲配信サービスでは、ユーザが自身の好きな楽曲を登録できる「お気に入り」機能が提供されている。そこで S-favorite では「 s をお気に入りに登録したユーザ数が x に到達したら、 u は s を聴くだろう」というルールを持つ。これら 3 種類の推薦理由では、推薦対象のユーザに馴染みのある楽曲が非常に多くのユーザによって聴かれたことやお気に入りに登録されたことを知った嬉しさから説得力を感じると仮定している。

3.2.3 コンテンツ的要因

コンテンツ的要因では、楽曲配信サービス上のユーザとは無関係に決まる、コンテンツ固有の要素を考慮する。コンテンツ的要因に関するスタイルとして、I-release と I-live の 2 種類を提案する。I-release でのルールは「 s が発売されてからちょうど x 年が経過したら、 u は s を聴くだろう」である。ここでは、そういった情報はユーザにとって楽曲の記念日のように感じられて楽曲を再度聴きたくなり説得力を感じると仮定している。I-live は「 s のアーティストが x 日前のライブで s を歌っていたら、 u は s を聴くだろう」というルールを持つ。ここでの仮定は、アーティストが最近のライブである楽曲を歌ったことを知ったユーザは、自分も「ライブ」感を楽しむためにその楽曲を聴きたくなり説得力を感じる、というものである^{*1}。

4. 調査実験

本章では 622 名を対象としたアンケート調査を実施することで以下の二つの疑問に答える。

RQ1 推薦理由の各スタイルは推薦理由の説得力にどのような影響を与えるか。

RQ2 推薦理由に含まれる変数の値と説得力との関係にはどのような傾向があるか。

4.1 参加者

アンケートの回答者は日本のアンケート会社を通じて募集した。回答者の条件として、任意の楽曲配信サービスのスマートフォンアプリを用いて平均的に週に 1 日以上楽曲を聴いていることと、日本人であることを設けた。回答者は Web ブラウザを通じて我々の用意したアンケートに回答した。各回答者には謝礼として 1,500 円を支払った。アンケートには 679 名が回答したが、分析結果をより信頼できるものにするために、57 名の回答を除外した (39 名は選択式の全ての質問に対して同じ番号を選んでいたので、18 名は自由記述の回答に対して「xxxxxx」などの不適切な回答をしたためであった)。残りの 622 名の性別と年代の分布は以下の通りである：男性 296 名 (10 代 8 名、20 代

60 名、30 代 82 名、40 代 73 名、50 代 73 名)、女性 326 名 (10 代 10 名、20 代 67 名、30 代 91 名、40 代 82 名、50 代 76 名)。

4.2 推薦理由の説得力

まず、RQ1 に答えるため、3.2 節で述べた 9 種類の各推薦理由の説得力を調査する。この調査では、推薦結果の良し悪しの影響を排除したうえで推薦理由の説得力を評価することを目的としている。そこで、推薦される楽曲によるバイアスを除くために、各推薦理由において、推薦される楽曲を「楽曲 A」と記述することとした。加えて、推薦理由の中で変数の値として記述される時間 (P-first, P-last, I-release, I-live)、再生回数 (P-total, S-total)、ユーザ数 (S-unique, S-favorite) のバイアスを除去するため、回答者には自分の好きな任意の値を想定するよう求めた。具体的には、P-first の場合であれば次のような説明文を回答者に提示した。

あなたが利用している楽曲配信サービス上で、あなたがある楽曲 (「楽曲 A」とします) を初めて再生してから今日でちょうど 5 年が経過しました。そこで、「初めて曲を聴いてからの経過時間」に基づく推薦理由では、「あなたが楽曲 A を初めて再生してから今日でちょうど 5 年が経過しました。」という推薦理由とともに楽曲配信サービス上で楽曲 A が推薦されます。ただし、ここで「5 年」と書いているのはひとつの例であり、半年、1 年、7 年などあなたの好きな時間を想定していただいて構いません。^{*2}

回答者は、各推薦理由に対する説得力を 7 段階 (1 は説得力が最も低く、7 は説得力が最も高い) で回答した。推薦理由は回答者ごとにランダムな順で提示した。ある推薦理由の説得力が 5 以上と回答した回答者 (つまり、その推薦理由に説得力があると感じた回答者) を対象として、その推薦理由に説得力があると感じた理由も自由記述形式で回答してもらった。

図 1 に各推薦理由の説得力の平均値を示す。9 種類の推薦理由は、説得力の高いグループ (P-together, P-total, S-total, S-unique, S-favorite, I-live) と説得力の低いグループ (P-first, P-last, I-release) に分けられる。チューキーの検定の結果、前者のグループのすべての推薦理由の説得力が、後者のグループのいずれの推薦理由の説得力よりも有意に高かった ($p < 0.05$) ことから、これら 2 グループの間には説得力に明確な違いがあると言える。

説得力の高いグループでは、P-together の説得力が最も

^{*1} ライブの参加者が、ライブで演奏された楽曲に関する情報を Twitter に投稿するのは一般的な行動である [17] ため、ライブに関する情報を収集する方法の一つとして Twitter の活用が考えられる。

^{*2} ユーザが楽曲 A を過去に聴いたことを覚えていなければ、楽曲 A は未知の楽曲として推薦する方が適切である。そのため本調査では、推薦された楽曲を過去に聴いたことは覚えているものと回答者には想定してもらった。




図 1 各推薦理由の説得力の平均値および標準誤差 (y 軸: 説得力の平均値)。

高く、S-total を除く残りの 7 種類のいずれの説得力よりも有意に高い値であった ($p < 0.05$)。我々の仮定どおり、P-together に説得力を感じる理由としては、懐かしさを感じられるからという理由が最も多かった。P-first と P-last についても仮定したとおり、懐かしさを感じるからという理由が最も多かったが、P-first と P-last はいずれも説得力の低いグループに含まれている。P-together の場合、ユーザは懐かしい楽曲を連続して (ユーザ自身が再生した楽曲と推薦された楽曲) 聴くことができるのに対して、P-first と P-last では推薦された楽曲だけに対して懐かしさを感じられる。そのため、P-together の方がユーザにより強く懐かしさを感じさせられるという点で、P-first と P-last よりも説得力が高い結果となった可能性がある。P-total に説得力を感じる理由として最も多かったのは、自身の総再生回数を知ること、いかにその楽曲のことが好きであるか再認識できるから、というものであった。我々が仮定していた理由 (達成感を感じられるから) は 2 番目に多い理由であった。

社会的要因に関しては、全ての推薦理由 (S-total, S-unique, S-favorite) が説得力の高いグループに属しており、それらの説得力の間には有意な差はなかった。いずれの推薦理由でも、楽曲が人気であることを実感できるからというのが説得力を感じる最も多い理由であった。より具体的には、S-total において、ある回答者は「自分の好きな楽曲がそれほどたくさん聴かれているとわかると嬉しくなるので、推薦された楽曲を聴きたい。」のように回答していた。

最後に I-live では、我々の仮定した理由 (ユーザが「ライブ」感を楽しむため) に加えて、アーティストの願望を汲み取った理由 (ライブで歌われた楽曲はアーティストが今聴いてほしい楽曲ということなので聴きたい) も多く見られた。

推薦対象となるユーザに対して楽曲を推薦する際は、そのユーザにとって説得力の高い推薦理由が採用されるべきである。しかし、そうした個々のユーザへの最適化にはユーザに対する事前調査など様々なコストが必要となる。




図 2 説得力のスタイル間でのピアソンの積率相関係数。いずれも無相関検定は棄却された ($p < 0.001$)。

そのような問題を解決するために、まずは説得力の高いグループに含まれる推薦理由を全ユーザに対して提示するというアプローチは楽曲配信プラットフォームにとって有益であると考えられる。

推薦理由の説得力について、スタイル間でピアソンの積率相関係数を計算した結果を図 2 に示す。P-first, P-last, I-release はいずれも説得力の低いグループに属しているが、互いに比較的高い相関を持つことから、時間に関する推薦理由に高い説得力を感じる回答者の集団が存在することがわかる。したがって、もしあるユーザが時間に関するいずれかの推薦理由とともに推薦された楽曲を聴いた場合、そのユーザは時間に関する他の推薦理由に基づいて推薦された楽曲も聴く可能性が高く、楽曲配信プラットフォームはこの知見に基づいて推薦する楽曲を決めることもできる。S-total, S-unique, S-favorite が互いに高い相関を持つため、楽曲の人気度に関する推薦理由に高い説得力を感じる回答者の集団がいることもわかる。その一方で、時間に関する推薦理由と楽曲の人気度に関する推薦理由の相関は低いことから、それぞれに説得力を感じる回答者の集団はある程度排他的であると言える。

4.3 推薦理由中の変数の値と説得力の関係

P-together を除く 8 種類の推薦理由には変数が含まれている。具体的には、P-first, P-last, I-release, I-live には時間に関する変数が含まれ、P-total と S-total には再生回数に関する変数が含まれ、S-unique と S-favorite にはユーザ数に関する変数が含まれる。本節では RQ2 に答えるため、推薦理由に含まれる変数の値に対する説得力を調査する。調査では、各推薦理由に対する変数の具体的な値を 4 件または 5 件回答者に提示した。例えば、P-total で提示された値は 50, 100, 300, 500, 1,000 の 5 件である。回答者は各値に対する説得力を 7 段階 (1 は説得力が最も低く、7 は説得力が最も高い) で回答し、そのように説得力を感じた理由も自由記述形式で回答した。各推薦理由に対する調査には、4.2 節において対応する推薦理由の説得力




図3 変数の値に対する説得力の平均値. y 軸の説得力の値の範囲は全てのグラフで共通である. 括弧内の数値は各スタイルの調査の参加者数を表す.

に5以上を付与した回答者だけが参加した.

8種類の各推薦理由において、回答者に対して提示した変数の値と、その値に対する説得力の平均値を図3に示す. いずれの推薦理由でも、 x 軸の変数の値の増加に伴って説得力の平均値は単調に増加または減少している. したがって、変数の値と説得力の関係には明確な傾向があると言える. 自由記述の内容を分析したところ、例えば P-first と P-last では、時間が長くなるほどより強く懐かしさを感じられるという理由で変数の大きい値に対して高い説得力を付与した回答者が多く見られた. 同様に人気度に関する推薦理由 (S-total, S-unique, S-favorite) でも、楽曲の人気度の高さをより強く感じられるという理由から、変数の値が大きくなるほど説得力の値は高くなっていった. それに対して I-live では時間が短い方が説得力の値が高かった. この理由としては、ライブで歌われてからより短い時間で楽曲を推薦されて聴くことで、アーティストとの一体感を感じられるからという回答が多かった. 以上の結果から、音楽配信プラットフォームが推薦理由を生成する際は、各推薦理由での説得力の平均値が例えば4以上の変数の値を用いるようなアプローチも有力であると考えられる.

5. おわりに

本稿では、繰り返し消費されるコンテンツを対象とした推薦理由の提示という概念を提唱し、9種類の推薦理由を提案した. さらに、アンケート調査を実施し、提案した各推薦理由の説得力および、推薦理由に含まれる変数の値に対する説得力を調査した. 本研究の限界点として、(1) 調査の対象が楽曲推薦のドメインだけである、(2) 実際のユー

ザのデータを使用して推薦理由を生成していない、(3) 日本人だけを対象としてアンケート調査を実施している、の三つがあげられる. こうした限界点はあるものの、繰り返し消費されるコンテンツを対象とした ER の有用性を調査した最初の研究として、ER の分野への貢献に値すると考えている. 複数の情報源を組み合わせた ER の初期の研究でも、文献 [16] は限界点 (1)、文献 [15] は限界点 (2) を有していたが、それらは後続研究に貢献してきている. 同様に限界点 (3) についても、国による各推薦理由の説得力の差異を調査するといったような、より発展的な研究課題の可能性も秘めている.

謝辞 本研究の一部は JST ACCEL (JPMJAC1602), JST CREST (JPMJCR20D4), JSPS 科研費 (20K19934) の支援を受けた.

参考文献

- [1] G. Adomavicius and A. Tuzhilin. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6):734–749, 2005.
- [2] A. Anderson, R. Kumar, A. Tomkins, and S. Vassilvitskii. The dynamics of repeat consumption. In *Proceedings of the 23rd International Conference on World Wide Web, WWW'14*, pages 419–430, 2014.
- [3] S. H. Bach, M. Broecheler, B. Huang, and L. Getoor. Hinge-loss markov random fields and probabilistic soft logic. *The Journal of Machine Learning Research*, 18(1):3846–3912, 2017.
- [4] A. R. Benson, R. Kumar, and A. Tomkins. Modeling user consumption sequences. In *Proceedings of the 25th International Conference on World Wide Web, WWW'16*, pages 519–529, 2016.
- [5] M. Bilgic and R. J. Mooney. Explaining recommen-

- dations: Satisfaction vs. promotion. In *Proceedings of Beyond Personalization 2005: A Workshop on the Next Stage of Recommender Systems Research at the 2005 International Conference on Intelligent User Interfaces*, IUI WS'05, pages 13–18, 2005.
- [6] S. Bostandjiev, J. O' Donovan, and T. Höllerer. TasteWeights: A visual interactive hybrid recommender system. In *Proceedings of the Sixth ACM Conference on Recommender Systems*, RecSys'12, pages 35–42, 2012.
- [7] S. Chang, F. M. Harper, and L. G. Terveen. Crowd-based personalized natural language explanations for recommendations. In *Proceedings of the 10th ACM Conference on Recommender Systems*, RecSys'16, pages 175–182, 2016.
- [8] J. Chen, C. Wang, and J. Wang. Will you “reconsume” the near past? Fast prediction on short-term reconsumption behaviors. In *Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence*, AAAI'15, pages 23–29, 2015.
- [9] J. Chen, C. Wang, J. Wang, and P. S. Yu. Recommendation for repeat consumption from user implicit feedback. *IEEE Transactions on Knowledge and Data Engineering*, 28(11):3083–3097, 2016.
- [10] J. L. Herlocker, J. A. Konstan, and J. Riedl. Explaining collaborative filtering recommendations. In *Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work*, CSCW'00, pages 241–250, 2000.
- [11] A. Kangasrääsio, D. Glowacka, and S. Kaski. Improving controllability and predictability of interactive recommendation interfaces for exploratory search. In *Proceedings of the 20th International Conference on Intelligent User Interfaces*, IUI'15, pages 247–251, 2015.
- [12] B. P. Knijnenburg, S. Bostandjiev, J. O' Donovan, and A. Kobza. Inspectability and control in social recommenders. In *Proceedings of the Sixth ACM Conference on Recommender Systems*, RecSys'12, pages 43–50, 2012.
- [13] D. Kotzias, M. Lichman, and P. Smyth. Predicting consumption patterns with repeated and novel events. *IEEE Transactions on Knowledge and Data Engineering*, 31(2):371–384, 2019.
- [14] P. Kouki, S. Fakhraei, J. Foulds, M. Eirinaki, and L. Getoor. HyPER: A flexible and extensible probabilistic framework for hybrid recommender systems. In *Proceedings of the 9th ACM Conference on Recommender Systems*, RecSys'15, pages 99–106, 2015.
- [15] P. Kouki, J. Schaffer, J. Pujara, J. O' Donovan, and L. Getoor. User preferences for hybrid explanations. In *Proceedings of the Eleventh ACM Conference on Recommender Systems*, RecSys'17, pages 84–88, 2017.
- [16] P. Kouki, J. Schaffer, J. Pujara, J. O' Donovan, and L. Getoor. Personalized explanations for hybrid recommender systems. In *Proceedings of the 24th International Conference on Intelligent User Interfaces*, IUI'19, pages 379–390, 2019.
- [17] A. Laplante, T. D. Bowman, and N. Aamar. “I’m at #Osheaga!”: Listening to the backchannel of a music festival on Twitter. In *Proceedings of the 18th International Society for Music Information Retrieval Conference*, ISMIR'17, pages 585–591, 2017.
- [18] J. O' Donovan, B. Smyth, B. Gretarsson, S. Bostandjiev, and T. Höllerer. PeerChooser: Visual interactive recommendation. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI'08, pages 1085–1088, 2008.
- [19] A. Papadimitriou, P. Symeonidis, and Y. Manolopoulos. A generalized taxonomy of explanations styles for traditional and social recommender systems. *Data Mining and Knowledge Discovery*, 24(3):555–583, 2012.
- [20] D. Parra, P. Brusilovsky, and C. Trattner. See what you want to see: Visual user-driven approach for hybrid recommendation. In *Proceedings of the 19th International Conference on Intelligent User Interfaces*, IUI'14, pages 235–240, 2014.
- [21] D. Rafailidis and A. Nanopoulos. Repeat consumption recommendation based on users preference dynamics and side information. In *Proceedings of the 24th International Conference on World Wide Web*, WWW'15 Companion, pages 99–100, 2015.
- [22] P. Ren, Z. Chen, J. Li, Z. Ren, J. Ma, and M. de Rijke. RepeatNet: A repeat aware neural recommendation machine for session-based recommendation. In *Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence*, AAAI'19, pages 4806–4813, 2019.
- [23] N. Sachdeva, K. Gupta, and V. Pudi. Attentive neural architecture incorporating song features for music recommendation. In *Proceedings of the 12th ACM Conference on Recommender Systems*, RecSys'18, pages 417–421, 2018.
- [24] P. Symeonidis, A. Nanopoulos, and Y. Manolopoulos. MoviExplain: A recommender system with explanations. In *Proceedings of the Third ACM Conference on Recommender Systems*, RecSys'09, pages 317–320, 2009.
- [25] N. Tintarev. Explanations of recommendations. In *Proceedings of the 2007 ACM Conference on Recommender Systems*, RecSys'07, pages 203–206, 2007.
- [26] N. Tintarev and J. Masthoff. Effective explanations of recommendations: User-centered design. In *Proceedings of the 2007 ACM Conference on Recommender Systems*, RecSys'07, pages 153–156, 2007.
- [27] K. Verbert, D. Parra, P. Brusilovsky, and E. Duval. Visualizing recommendations to support exploration, transparency and controllability. In *Proceedings of the 2013 International Conference on Intelligent User Interfaces*, IUI'13, pages 351–362, 2013.
- [28] Y. Zhang and X. Chen. Explainable recommendation: A survey and new perspectives. *Foundations and Trends in Information Retrieval*, 14(1):1–101, 2020.
- [29] Y. Zhang, G. Lai, M. Zhang, Y. Zhang, Y. Liu, and S. Ma. Explicit factor models for explainable recommendation based on phrase-level sentiment analysis. In *Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval*, SIGIR'14, pages 83–92, 2014.