

# 楽曲の繰り返し推薦におけるヒトの認知特性の活用

重富竜ノ介<sup>†</sup> 牛尼 剛聡<sup>††</sup>

<sup>†</sup>九州大学大学院芸術工学府 〒815-8540 福岡市南区塩原 4-9-1

<sup>††</sup>九州大学大学院芸術工学研究院 〒815-8540 福岡市南区塩原 4-9-1

E-mail: <sup>†</sup>shigetomi.ryunosuke.408@s.kyushu-u.ac.jp, <sup>††</sup>ushiyama@design.kyushu-u.ac.jp

**あらまし** 音楽は繰り返して消費されることが多いコンテンツである。そのため、ユーザが既知の楽曲を対象とした繰り返し推薦に関する研究が注目されている。一方、音楽などの刺激に対するヒトの快感情は、同じ刺激を繰り返すことによって逆 U 字型に変化するという認知特性が知られている。本研究では、この認知特性を楽曲推薦に活用し推薦性能を向上させることを目的とする。本論文では、はじめに音楽ストリーミングサービスの大規模データセットを分析し、繰り返しによる快感情の逆 U 字型変化がユーザの繰り返し聴取パターンに影響を及ぼしていることを検証する。次に、繰り返し回数を変数として快感情が変化するモデルによってユーザのある楽曲に対する快感情を予測する手法を提案する。最後に、このモデルを推薦システムのリランキングに用いた際の性能を評価した結果を示す。

**キーワード** 繰り返し推薦, 楽曲推薦, 認知特性

## 1 はじめに

音楽ストリーミングサービスにおいて、膨大な量のコンテンツからユーザが自身の好みに適合する楽曲を発見するのは困難である。そこで、良質な楽曲推薦を行いユーザ満足度を向上させるために様々な楽曲推薦手法が提案されている。代表的な楽曲推薦手法のアプローチとして、プレイリスト推薦 [1]、コンテキストウェア推薦 [2]、推薦理由の提示 [3] などがある。また、新規楽曲の推薦においては、セレンディピティに注目した推薦など新しい視点からの提案も行われている。

楽曲は繰り返し消費される割合が高いコンテンツであることから [4], [5]、楽曲の繰り返し推薦に関する研究が活発に行われている。Haas ら [6] の研究によると、ユーザが過去に聴取した楽曲の約 66 % が再聴取されている。繰り返し消費とは、例えば、同じ楽曲を短い期間で何度も聴取し、その後コンテンツに飽きるに従って聴取間隔が長くなり、最終的には消費しなくなるというような行動である [5]。

これまでに、再帰的ニューラルネットワーク (RNN) [7] やグラフニューラルネットワーク (GNN) [8] などを用いた繰り返し消費を対象とした推薦手法が提案されている。これらの手法ではユーザの過去のセッションに基づいて推薦を行っている。セッションとは、ある時間枠の中で行われるユーザとアイテムのインタラクションの集合である。例えば、ユーザ聴取履歴の中で、5 分以上間隔が空いていない連続した楽曲の集合は 1 つのセッションと考えることができる。セッションを用いた推薦をセッションベース推薦といい、セッション内の逐次的なパターンやセッション間のアイテム同士の関係を学習することで、次のセッションのアイテムを予測する [9], [10]。

一方、音楽は繰り返し聴取することで、認知度と高感度が上がり、快感情が逆 U 字型に変化することが知られている [12]。この特徴を考慮すると、初めは快感情が低い楽曲でも、繰り返

して聴取することで快感情が増加し、ユーザにとっての価値が向上する可能性がある。そこで、このようなヒトの楽曲に対する認知特性を考慮した推薦システムの重要性が主張されている [6], [13], [14]。

Ren ら [11] は忘却曲線に従い、過去の聴取履歴ほど現在の嗜好への影響が少ないことを利用した重み付き協調フィルタリングを提案している。また、Haas ら [6] はヒトの記憶に関する認知特性をモデル化した Adaptive Control of Thought-Rational (ACT-R) [6] を用いて認知特性を考慮した繰り返し推薦手法を提案している。Sguerra ら [14] は音楽ストリーミングサービスにおける、繰り返しによる快感情の逆 U 字型変化の影響を調査した。分析によって、聴取確率が繰り返しによって逆 U 字型に変化していることが確認されている。

本論文では、快感情の変化を聴取間隔の変化に置き換え、繰り返しによる聴取間隔の変化を検証する。快感情が高いほど聴取間隔は短く、快感情が低いほど聴取間隔は長いと仮定すると、繰り返しによって快感情が逆 U 字型に変化するならば、聴取間隔は U 字型に変化することが予想される。音楽ストリーミングサービス LAST.FM のデータセットを用いた分析によって、繰り返しによる聴取間隔の U 字型変化を分析する。

分析結果をもとに、繰り返し回数によって快感情を予測するモデルを構築し、既存手法のリランキングに用いることで、認知特性を考慮した楽曲推薦の有効性を示す。

2 章で先行研究と本研究の関連性について述べた後、3 章でデータセット及び繰り返し聴取に関する分析を説明する。さらに、4 章で提案手法を説明し、5 章で実験方法について述べた後、6 章で結果の説明及び考察を行う。最後に 7 章でまとめと今後の展望について述べる。

## 2 関連研究

これまでも、繰り返し推薦と繰り返し聴取による心理学的

な影響について活発に研究が行われてきた。2.1節では、繰り返し推薦について、2.2節では繰り返し聴取によるヒトの心理への影響とその推薦への応用について先行研究を紹介し、本研究との関連について述べる。

## 2.1 繰り返し推薦

音楽は繰り返し消費されることは上で述べたが、インターネットコマースや飲食店などでも繰り返し消費の割合が高いことが知られている [4]。そのため、繰り返し消費されるアイテムに適応可能な一般的な手法が提案されている。

Anderson ら [4] はソーシャルメディアのログイン、Wikipedia の閲覧や YouTube の再聴取など、様々な領域での繰り返し消費を分析した。その結果、最後の消費からの経過時間が繰り返し消費の最も強い予測因子であることを明らかにした。

Benson ら [5] は、繰り返し消費するアイテムには飽きと寿命があることを明らかにした。繰り返し消費するアイテムでも、その消費間隔は徐々に大きくなり最後の消費では最初の間隔に比べて 3~5 倍の差があることを確認した。

近年では、ユーザの直近の消費がその後の消費に大きく関わることに注目して、セッションベース推薦が提案されている。

Ren ら [7] は RNN を用いたセッションベース推薦を繰り返し消費に応用した手法を提案している。この手法では、まずセッションを RNN を用いてエンコードした後、*repeat mode* と *explore mode* によって新規コンテンツの推薦と過去に消費したことのあるコンテンツの推薦をそれぞれ行う。そして、*repeat-explore mechanism* によって *repeat mode* と *explore mode* の実行確率を求めることで、過去に消費したことのあるコンテンツと新規コンテンツを考慮したセッションベース推薦を提案している。

Hansen ら [2] は、セッションベースの楽曲推薦 CoSeRNN を提案している。これは、コンテキストとシークエンスに基づく楽曲推薦モデルである。あるセッションに含まれる楽曲ベクトルの平均であるセッションベクトルとともに、聴取時間帯やデバイスなどのコンテキスト情報を LSTM に入力し、次のセッションの楽曲を予測する。

これらのモデルは、ユーザの楽曲に対する認知特性を考慮しておらず、例えば繰り返すことで徐々に快感が上がりさらに繰り返すことで快感が低下することをモデルに組み込んでいない。本研究で聴取回数を利用することで、ユーザの楽曲に対する快感が変化することを考慮した推薦システムを実現する。

## 2.2 繰り返し聴取によるヒトの心理への影響と推薦への応用

音楽を含めた刺激に対する一般的な認知特性として、繰り返し刺激を与えられると、その刺激に対する快感が逆 U 字型に変化する、というものがある [12]。図 1 のように刺激を何度も繰り返すことでその刺激に対する快感が増加していく。さらに刺激を繰り返すことである閾値を迎えると快感は最大化し、その後は減少していく。

この曲線は刺激の不確かさによって変化し、一般的には、より不確かさが大きな刺激ほど曲線の最大値へ達するまでに時間




図 1 繰り返し刺激による快感の逆 U 字型変化

を要する [15]。また、刺激の受容者によってもこの曲線は変化する。例えば、音楽では、あるジャンルに親しみのあるユーザにとっては不確かさの低い楽曲も、そのジャンルに親しみのないユーザにとっては不確かさが高く、曲線のピークに達するために必要な刺激の回数が多くなる。

Sguerra ら [14] は、この快感の逆 U 字型変化の影響が、音楽ストリーミングサービスのユーザ聴取履歴に現れていることを示した。ある楽曲の聴取確率は聴取回数に対して逆 U 字型に変化することを明らかにした。また、この曲線は楽曲によって異なり、例えば新曲では聴取確率が逆 U 字型の変化を示すが、ビートルズなどの誰もが知っている楽曲は聴取確率が徐々に減少していく。

これらの実験結果により、楽曲の繰り返し聴取にはヒトの認知特性が大きく関わっていることが示されている。このようなヒトの認知特性を考慮してすることにより、ユーザにとって快感が高い楽曲を推薦することが可能となる。

Haas ら [6] が提案した認知アーキテクチャ ACT-R を用いた推薦システムは、ヒトの記憶に関する認知特性をモデル化した推薦システムである。ヒトの認知特性を考慮すると、間近に頻繁に聴取している、間近の聴取楽曲と共起している、間近の聴取楽曲と類似度が高いなどの楽曲が繰り返し聴取されやすいことを利用した推薦システムである。しかし、現状のシステムでは、繰り返し聴取のみをモデル化しているため、新規楽曲推薦を考慮していない。そのため、従来の推薦手法やニューラルネットワークを用いた推薦手法と組み合わせることでより良い性能を発揮する可能性がある。

L.Ren [11] が提案した、time enhanced collaborative filtering では、協調フィルタリングのユーザ間類似度及びアイテム間類似度の計算時、コンテンツの最後の消費からの経過時間によってバイアスをかけることで、忘却曲線を活用した推薦システムを提案している。例えば、あるユーザから高評価を得ているコンテンツでも、その消費から現在までの経過時間が長くなるほど強いバイアスがかけられ、低い評価値として計算に利用される。ここで用いられている認知特性は忘却曲線のみだが、Haas らのように複数の認知特性を組み合わせることで精度向

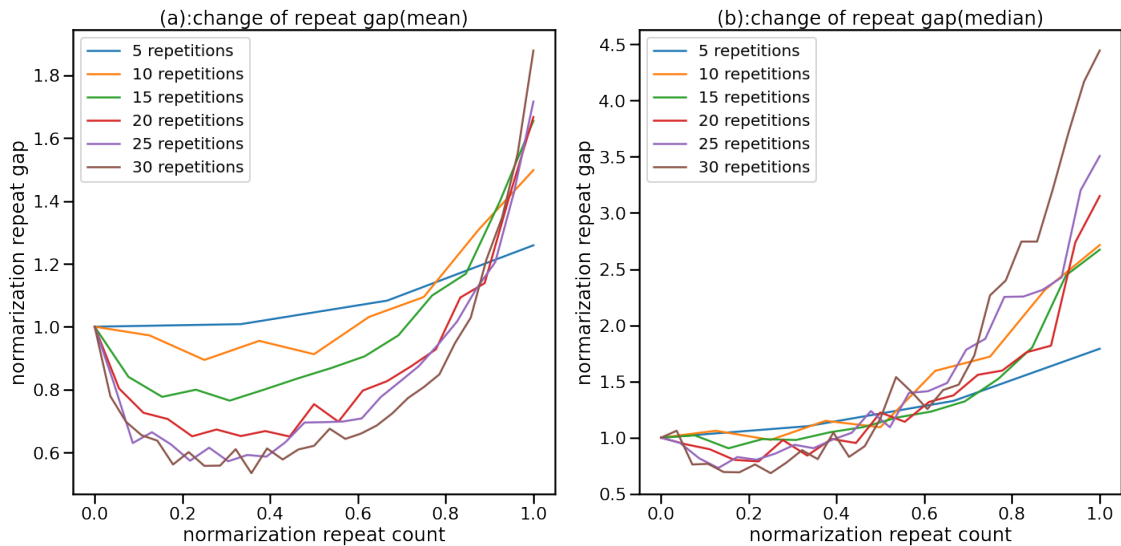


図 2 繰り返し聴取による聴取間隔の U 字型変化：(a) 平均 (b) 中央値

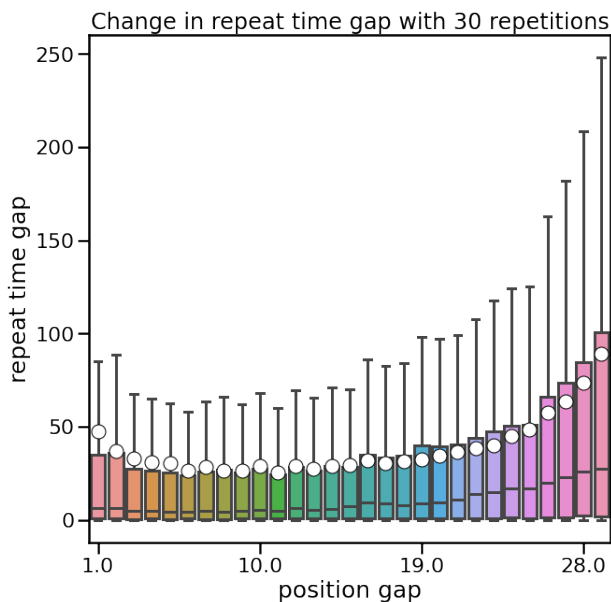


図 3 最大聴取回数 30 における聴取間隔の U 字型変化

上に寄与する可能性がある。

本研究ではまず、繰り返しによる快感情の逆 U 字型変化の影響がユーザの聴取確率だけでなく聴取間隔に現れていることを示す。次に、繰り返しによる快感情の変化をモデル化し、推薦システムのリランキングに用いる。最後に、その推薦精度を評価し、認知特性を考慮した楽曲推薦の有効性を検証する。

### 3 快感情の逆 U 字型変化によるユーザ聴取パターンへの影響

#### 3.1 データセット

繰り返し聴取による快感情の逆 U 字型変化のユーザ聴取パターンへの影響を検証するため、音楽ストリーミングサービス LAST.FM のデータセットである LFM-2b Dataset を用いて分析を行った。

LAST.FM の 2020-1-1 から 2020-3-20 までのユーザ聴取履歴であり、userId, trackId, albumId, timestamp が含まれる。

データの規模は、ユーザ数 15,258 人、楽曲数 4,082,530 曲、30,357,786 レコードである。

#### 3.2 繰り返し聴取による聴取間隔の変化

繰り返しによる快感情の逆 U 字型変化のユーザ聴取パターンへの影響を明らかにするため、繰り返し聴取による聴取間隔の変化を分析した。

図 4 は繰り返し聴取による聴取間隔の U 字型変化を可視化したものである。各最大聴取回数 (5,10,15,...,30 回) のシーケンスに対して、それぞれの聴取回数毎 (1,2,3,... 回目) に聴取間隔の平均と中央値を計算し、正規化してプロットしている。正規化方法は、最初の聴取間隔を 1 とした時のその後の聴取間隔の割合である。また横軸は、異なる最大聴取回数のシーケンスを同じグラフ内にプロットするために繰り返し回数を各最大聴取回数毎に最小値と最大値で正規化したものである。

分析から、繰り返しによって聴取間隔が U 字型に変化する傾向を確認することができ、最大聴取回数が多い楽曲ほどその傾向が強いことが明らかになった。

また、平均値と中央値のグラフで傾向に差があることから、Sguerra ら [14] が示しているように楽曲によって快感情の変化のパターンに相違があることも読み取れる。これは、図 3 に示した最大聴取回数 30 での各聴取回数の聴取間隔の箱ひげ図からも説明することができる。平均値や最大値はおおよそ U 字型に変化しているが、分散が大きく、楽曲によってはこのパターンに当てはまらないものも含まれることが考えられる。Sguerrara ら [14] や [5] らの研究から考えると、ユーザの繰り返し聴取間隔のパターンには、主に U 字型の変化と増加のパターンがあることが考えられる。これは、楽曲の不確定さによって快感情が逆 U 字型になるものと徐々に減少するものがある事実とも一致する。

次章では、この分析結果をもとに、聴取回数によって快感情

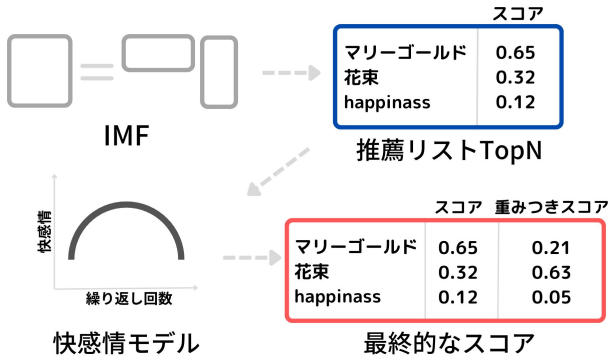


図4 提案手法の概略図

を予測するモデルを提案し、このモデルの推薦システムへの利用方法を説明する。

## 4 提案手法

提案するヒトの認知特性を活用した推薦システムの概要図を図4に示す。行列因子分解[17]で得た推薦リストtopNに対して、繰り返しによる快感情の変化を考慮したモデルによって重みをかけ、リランキングしたものを最終的な推薦スコアとする。以下でそれぞれの詳細について述べる。

### 4.1 暗黙的な評価値に対する行列因子分解

LAST.FM や Spotify など、一般に普及している音楽ストリーミングサービスにおいて、ユーザの楽曲に対する評価は暗黙的であることが多い。例えば、「楽曲を聴取したかどうか、途中で聴取をやめたかどうか」といった暗黙的な評価を推薦に活用する必要がある。

本研究では、暗黙的な評価値に対する行列因子分解 (Implicit Matrix Factorization : IMF) [17] を用いて、ユーザの楽曲聴取履歴を用いた推薦を行う。IMF は通常の明示的な評価値に対する行列因子分解 [16] を暗黙的な評価値に適応させたものである。基本的なコンセプトは明示的な評価値に対する行列因子分解と同様であり、評価値行列から低次元のユーザ因子行列とアイテム因子行列を作り、その内積を取ることでユーザとアイテムの相性を予測するものである。

IMF では、観測値  $r_{ui}$  としてアイテム  $i$  に対するユーザ  $u$  のインタラクションの数を用いる。例えば楽曲推薦の場合、ユーザのある楽曲に対する聴取回数が観測値となる。この観測値は明示的な評価ではないため、ユーザの好みを直接表していない。そのため、観測値をユーザのアイテム  $i$  に対する好意  $\bar{r}_{ui}$  とその好意の信頼度  $c_{ui}$  に分解することで暗黙的な評価を行列因子分解に利用することができる。

ユーザのアイテム  $i$  に対する好意  $\bar{r}_{ui}$  は、(1) 式のようにアイテムを一度でも見たかどうかで二値化したものである。

$$\bar{r}_{ui} = \begin{cases} 1 & (r_{ui} > 0) \\ 0 & (r_{ui} = 0) \end{cases} \quad (1)$$

この好意に対して (2) 式で表される信頼度  $c_{ui}$  を用いることで、その好意がどれだけ信頼できるものかを定義する。

$$c_{ui} = 1 + \alpha r_{ui} \quad (2)$$

例えば、ある楽曲に対して、ユーザの聴取回数が1回であるより10回のほうが好意の信頼度が高くなり、逆に0回である場合は、好みでない可能性の他にも、そもそもその楽曲を知らない可能性もあるため信頼度は低くなる。

IMF では、これらの好意  $\bar{r}_{ui}$  と信頼度  $c_{ui}$  を用いて、(3) 式を最適化することで推薦スコアを計算している。

$$\min_{p,q} \sum_{u,i} c_{ui} (\bar{r}_{ui} - p_u^T q_i)^2 + \lambda \left( \sum_u \|p_u\|^2 + \sum_i \|q_i\|^2 \right) \quad (3)$$

ここで、 $u$  はユーザ、 $i$  は楽曲、 $p$  はユーザ因子行列、 $q$  はアイテム因子行列である。ユーザ  $u$  のアイテム  $i$  の聴取回数が多いほど、 $c_{ui}$  が大きくなる。この時、 $\bar{r}_{ui} = 1$  であるため、 $p_u^T q_i$  が1に近づくように学習が進行する。

### 4.2 快感情の逆U字型変化による重み付け

次に、IMF で算出したそれぞれのユーザについての推薦アイテム TopN に対して、快感情モデルによる重み付けを行う。本研究では、(4) 式のように、単純な2次関数を用いることで、繰り返しによって快感情が変化することをモデル化している。

$$v_{ui} = \begin{cases} \frac{1}{m^2} (n_{ui} - m)^2 + 1 & (n_{ui} < 2m) \\ \frac{1}{m^2} (2m_{ui} - 1 - m)^2 + 1 & (n_{ui} \geq 2m) \end{cases} \quad (4)$$

ここで、 $v$  は予測快感情値、 $n_{ui}$  はユーザ  $u$  のアイテム  $i$  に対する聴取回数、 $m$  は快感情が最大となる繰り返し回数である。

この関数は、快感情の値が繰り返し聴取によって徐々に増加し、ある聴取回数で最大値1となりその後減少することで、快感情の逆U字型変化をモデル化している。

聴取回数  $n$  が大きくなり2次関数の値が0以下になる場合は、その1つ前の  $n$  を入力として快感情  $v$  を計算する。これは、推薦スコアが0以下になることを防ぐためである。

以上のような関数によって IMF の推薦アイテム TopN を重み付けする。最終的な推薦スコア  $s_{ui}$  は5式で表される。

$$s_{ui} = \begin{cases} v_{ui} s_{ui}^{IMF} & (n_{ui} > 0) \\ 0.5 s_{ui}^{IMF} & (n_{ui} = 0) \end{cases} \quad (5)$$

ユーザ  $u$  のアイテム  $i$  に対する聴取回数  $n_{ui}$  が0以上の場合、IMF の推薦スコア  $s_{ui}^{IMF}$  に  $v_{ui}$  で重み付けしたものを最終的な推薦スコアとする。一方、 $n_{ui}$  が0の場合 (ユーザ  $u$  にとっての新規楽曲)、 $s_{ui}^{IMF}$  に対して一律に0.5で重み付けを行う。

## 5 実験

ユーザの聴取履歴の最新の20件をテストデータとし、残りを学習データとした。また、総聴取回数が200件未満のユーザを削除するとともに、楽曲についても全ユーザからの聴取回数が50回以下のものを削除した。さらに、ユーザ  $u$  の楽曲  $i$  に

表 1 実験 1：提案手法と従来手法の比較及び快感情モデルを変化させた際の影響

	Recall@10	Recall@20	MRR@10	MRR@20
POP	0.0000235	0.0000391	0.000151	0.000168
IMF (新規のみ)	0.00499	0.00832	0.027	0.029
IMF	0.0287	0.0472	0.125	0.130
IMF+快感情 6	0.0203	0.0365	0.0894	0.0958
<b>IMF+快感情 prop</b>	<b>0.0331</b>	<b>0.0522</b>	<b>0.153</b>	<b>0.157</b>
<b>IMF+快感情 log</b>	<b>0.0331</b>	<b>0.0522</b>	<b>0.153</b>	<b>0.157</b>

表 2 実験 2：提案手法において快感情が最大となる繰り返し回数  $m$  を変化させた際の影響

	Recall@10	Recall@20	MRR@10	MRR@20
IMF + 快感情 3	0.218	0.0426	0.0861	0.093
<b>IMF + 快感情 6</b>	<b>0.0203</b>	<b>0.0365</b>	<b>0.0894</b>	<b>0.0958</b>
IMF + 快感情 12	0.0255	0.0425	0.117	0.122
IMF + 快感情 24	0.0296	0.048	0.136	0.141
IMF + 快感情 48	0.321	0.0508	0.145	0.150
<b>IMF + 快感情 96</b>	<b>0.0327</b>	<b>0.0516</b>	<b>0.149</b>	<b>0.154</b>

対する聴取回数が 4 以上のもののみを評価値行列に用いた。つまり、好意  $\bar{r}_{ui}$  は (6) 式となる。

$$\bar{r}_{ui} = \begin{cases} 1 & (r_{ui} > 3) \\ 0 & (r_{ui} = 0) \end{cases} \quad (6)$$

最後に、IMF のパラメータチューニングを行い、因子数 546、エポック数 8、 $\alpha = 10$  として実験を行った。

## 5.1 評価

### 5.1.1 評価指標

4 節で行った提案手法の評価を Recall@10, Recall@20, MRR@10, MRR@20 を用いて行った。Recall@k は、予測アイテムの集合が適合アイテムの集合をどれだけ予測できたかを示す。MRR@k は推薦リストにおけるランキングのうち、最初の適合アイテムがどれだけ上位に位置しているかを示す。

### 5.1.2 比較手法

実験 1 において、従来手法との比較及び快感情のモデルを比例関数や対数関数に変化させた際の影響を調査した。また、実験 2 において、提案手法で快感情が最大となる繰り返し回数  $m$  を変化させた際の影響を調査した。

以下にそれぞれの実験で対象とした手法の詳細を示す。

### 5.1.3 実験 1

実験 1 で対象とした手法を以下に示す。

- **POP**：アイテムの人気順の推薦。全ユーザーで人気かつユーザー  $u$  が聴取していない楽曲を推薦する。
- **IMF (新規のみ)**：IMF のみでユーザー  $u$  にとっての新規楽曲のみを推薦する。
- **IMF**：IMF のみでユーザー  $u$  にとっての新規楽曲と繰り返し楽曲を推薦する。
- **IMF + 快感情 6**： $m = 6$  としたものの。
- **IMF + 快感情 prop**：快感情を比例関数でモデル化したものの。  $v_{ui} = \frac{1}{96}n$ 。
- **IMF + 快感情 log**：快感情を対数関数でモデル化したものの。  $v_{ui} = \log(0.02n) + 1$ 。

### 5.1.4 実験 2

実験 2 で対象とした手法を以下に示す。

- **IMF + 快感情 3**： $m = 3$  としたものの。
- **IMF + 快感情 6**： $m = 6$  としたものの。
- **IMF + 快感情 12**： $m = 12$  としたものの。
- **IMF + 快感情 24**： $m = 24$  としたものの。
- **IMF + 快感情 48**： $m = 48$  としたものの。
- **IMF + 快感情 96**： $m = 96$  としたものの。

## 6 結果と考察

表 1 に実験 1 の結果を示す。IMF + 快感情 prop, IMF + 快感情 log などの快感情が繰り返し回数によって増え続けるモデルが、すべての評価指標において最も優れた性能を示した。一方、IMF + 快感情 6 は、IMF のみと比べて低い性能となった。

実験 2 の結果を表 2 に示す。 $m$  が大きくなるほど、性能が向上していることがわかる。しかし、実験 2 において最も性能が優れていた IMF+快感情 96 よりも、IMF + 快感情 prop, IMF + 快感情 log などの快感情が繰り返し回数によって増え続けるモデルの精度が高いことがわかった。

実験 1 と実験 2 の結果から、繰り返し回数が多い楽曲ほど再聴取される確率が高いことが考えられる。これは、Anderson ら [12] らが一般的な繰り返し行動を分析した結果と一致する。これらの結果から、統計的には、過去に繰り返し消費している回数が多いアイテムほど、再び繰り返すことが多いことがわかる。これは、長期的な視点では繰り返し聴取することによる「不快」な感情の想起が少ないことを意味している。例えば、楽曲に飽きた後、しばらく期間を開けた後に聴取すると、好意を再び感じたり懐かしさを感じたりする現象で説明することができる。

しかし、短期的な視点では Benson ら [5] が示している「飽き」や Sguerra ら [14] および本論文 3 節が示している「快感情の逆 U 字型変化」を予測することは重要であると考えられる。また、長期的な視点においても、一度飽きてしまった楽曲の快



感情が回復するタイミングを予測することは重要であると考えられる。

今後の研究では、3節で用いた聴取間隔や聴取頻度による、快感情変化の時系列予測に焦点を当てる。ユーザのある楽曲に対するこれまでの楽曲聴取パターンを利用することで、次の聴取タイミングを予測し楽曲推薦に応用する。

## 7 おわりに

本論文では、まず、ある楽曲を繰り返し聴取することによる快感情の逆U字型変化が、ユーザの聴取間隔に影響を与えていることを検証した。オンライン音楽ストリーミングサービスLAST.FMの大規模なデータセットを分析した結果、繰り返し聴取によって聴取間隔がU字型に変化していることがわかった。快感情が高いと聴取間隔が短く、逆感情が低いと聴取間隔が長いと仮定すると、この結果は快感情の逆U字型変化による影響を受けたものと解釈できる。

次に、分析結果をもとに、IMFの推薦リストtopNに対して快感情モデルによるリランキングを行うことでヒトの認知特性を活用した推薦システムを提案し評価した。その結果、繰り返す回数が多い楽曲を再度繰り返して推薦するモデルの有効性が示された。

しかし、短期的な視点では、「飽き」や「快感情の逆U字型変化」が、長期的な視点では「時間経過による快感情の回復」が重要であるため、今後の実験によって聴取間隔や聴取頻度を用いた快感情の時系列変化予測を行う。また、聴取間隔や聴取頻度以外にも、逆U字型変化の影響を受ける特徴量は存在する可能性があり、その探索も今後の重要な研究テーマである。

## 謝 辞

本研究はJSPS科研費19H04219の助成を受けたものです。

## 文 献

- [1] Z. Chedrawy Z, S. Sibte, and R. Abidi: "A web recommender system for recommending, predicting and personalizing music playlists", *Web Information Systems Engineering*, pp 335-342 (2009) .
- [2] C. Hansen, C. Hansen, L. Maystre, R. Mehrotra, B. Brost, F. Tomasi, and M. Lalmas: "Contextual and Sequential User Embeddings for Large-Scale Music Recommendation", *In Fourteenth ACM Conference on Recommender Systems, RecSys ' 20*, pp 10 (2020) .
- [3] K. Tsukuda and M. Goto. "Explainable Recommendation for Repeat Consumption", *Fourteenth ACM Conference on Recommender Systems, Association for Computing Machinery*, pp 462 - 467 (2020) .
- [4] A. Anderson, R. Kumar, A. Tomkins, and S. Vassilvskii: "The dynamics of repeat consumption", *In Proceedings of the 23rd International Conference on World Wide Web, WWW' 14*, pages 419 - 430, 2014.
- [5] 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*, pp 519 - 529 (2016) .
- [6] M. Haas, E. Cabaleiro, M. Schedl, E. tamedi, M. Tkalcic,

- and E. Lex: "Predicting Music Relistening Behavior Using the ACT-R Framework", *In Fifteenth ACM Conference on Recommender Systems, RecSys ' 21*, pp 6 (2021) .
- [7] 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", *Association for the Advancement of Artificial Intelligence, AAAI*, pp 4806-4813 (2019) .
- [8] X. Xian, L. Fang and S. Sun: "ReGNN: A Repeat Aware Graph Neural Network for Session-Based Recommendations", *in IEEE Access*, pp 98518-98525 (2020) .
- [9] Z. Cheng, J. Shen, L. Zhu, M Kankanhalli, and L. Nie: "Exploiting music play sequence for music recommendation", *In IJCAI ' 17*, pp 3654 - 3660 (2017) .
- [10] M. Quadrana, A. Karatzoglou, B. Hidasi, and P. Cremonesi: "Personalizing session-based recommendations with hierarchical recurrent neural networks" *In RecSys ' 17*, (2017) .
- [11] L. Ren: "A Time-Enhanced Collaborative Filtering Approach", *2015 4th International Conference on Next Generation Computer and Information Technology (NGCIT)*, pp 7-10 (2015) .
- [12] D. Berlyne: "Aesthetics and psychobiology", *Journal of Aesthetics and Art Criticism*, pp 553-553 (1971) .
- [13] J. Anderson, D. Bothell, M. Byrne, S. Douglass, C. Lebiere, and Y. Qin: "An integrated theory of the mind", *Psychological review*, pp 1036 (2004) .
- [14] Bruno Sguerra, Viet-Anh Tran, and Romain Hennequin: "Discovery Dynamics: Leveraging Repeated Exposure for User and Music Characterization", *Proceedings of the 16th ACM Conference on Recommender Systems (RecSys '22)*. pp 556 - 561(2022).
- [15] D. Berlyne: "Novelty, complexity, and hedonic value", *Perception and Psychophys*, pp 279 - 286 (1970) .
- [16] Y. Koren, R. Bell and C. Volinsky, "Matrix Factorization Techniques for Recommender Systems", *in Computer*, vol. 42, no. 8, pp. 30-37 (2009) .
- [17] Y. Hu, Y. Koren and C. Volinsky, "Collaborative Filtering for Implicit Feedback Datasets", *2008 Eighth IEEE International Conference on Data Mining*, pp. 263-272 (2008) .
- [18] J. Gu, Z. Lu, H. Li, and V. O. Li: "Incorporating copying mechanism in sequence-to-sequence learning", *In ACL ' 16*, (2016) .