

# アイテム選択の持続性を用いた Last.FM ユーザの分類と再生の予測

武井 淳也<sup>†</sup> 森澤 竣<sup>‡</sup> 渡邊 充博<sup>¶</sup> 山名 早人<sup>§</sup>

<sup>†</sup> <sup>‡</sup> <sup>¶</sup> 早稲田大学基幹理工学部 〒169-8555 東京都新宿区大久保 3-4-1

<sup>§</sup> 早稲田大学理工学術院 〒169-8555 東京都新宿区大久保 3-4-1

E-mail: <sup>†</sup> <sup>‡</sup> <sup>§</sup> <sup>¶</sup> {junya, hiroshun, mwatanabe, yamana}@yama.info.waseda.ac.jp,

**あらまし** 近年の音楽推薦システムでは、プレイリストによる推薦が主流となっている。また推薦システムの目的の一つは、ユーザに負担となるアイテム選択のコストを削減することである。ユーザの負担として特に大きいのは「ある曲を連続して聞きたいにも関わらず、別の曲が推薦されること」にある。つまり、アイテム（曲）選択の持続性がパーソナライズされていないという課題がある。本研究では、各ユーザの曲毎にアイテム選択の持続性を予測し、音楽推薦システムの一機能として取り入れることを目指した。ここで、アイテム選択の持続性とは「一定期間内に同じ曲を再生する回数」を示す。さらに、アイテム選択の持続性の予測精度向上のために、アイテム選択の持続性は個人的特徴に依存しているという仮説を検証した。まず、アイテム選択の持続性を表す個人的特徴を、一定期間単位の同じ曲の再生回数の増減分布として定義した。そして、各ユーザの曲毎に、週単位での同じ曲の再生回数の増減によって、次週の再生回数の増減を予測する 2 値分類モデルの学習を行った。予測モデルには、Random Forest を用いた。結果として、ベースラインと比較して 8.42% 精度が向上した。ベースラインは、週単位での同じ曲の再生回数の増減の正負のみにより予測した手法の結果とした。ベースラインの予測モデルは、Random Forest を用いた。次に、アイテム選択の持続性は個人的特徴に依存するという仮説を検証するために、同一曲を再生する回数の増減の分布を表す特徴を用いてユーザのクラスタリングを行った。そして、同様の方法で、クラスタごとに学習、予測を行った。クラスタ数を変えて予測精度の計測を行った結果、ユーザを 7 つのクラスタにクラスタリングして学習、予測を行った場合に、最も高い 77.17% の予測精度を達成し、ユーザをクラスタリングせずにすべてのユーザで学習、予測を行った場合と比較して 7.42% 向上した。

**キーワード** 情報推薦, 音楽推薦システム, アイテム選択の持続性

## 1. はじめに

Amazon<sup>1</sup>, Netflix<sup>2</sup>, Alibaba<sup>3</sup>, Spotify<sup>4</sup> などオンラインコマースの普及によって顧客（ユーザ）がより多くの商品（アイテム）を選べるようになった。一方、ユーザがアイテムを選択する時にかかるコストは増大している。推薦システムは、そういった選択のコストを抑えるために有効な手段である。近年の音楽推薦システムは、プレイリストによる推薦が主流となっている [1]。音楽のプレイリスト推薦においてアイテム選択のコストを削減することを考慮すると、推薦されたプレイリスト内の曲が飛ばされずに再生されることは重要である。すなわち、ユーザの再生する曲を予測することが重要である。

ユーザに推薦する音楽は「初めて聞く曲」と「聞いたことがある曲」に分けることができる。多くの音楽推薦システムに関する研究 [2][3][4][5][6][7] では

「初めて聞く曲」の推薦に着目し、その精度向上を目指しているが、「聞いたことがある曲」を適切に推薦することも重要である。特に「聞いたことがある曲」の中でも、同じ曲を繰り返す回数はユーザによって異なり、ユーザの満足度を向上させるには、どの程度「聞いたことがある曲」の推薦を繰り返せばよいかが課題となる。

本研究では、「聞いたことがある曲」をどのように推薦するかという点に着目し、最終的には音楽推薦システムの一機能として取り入れるべく、「ユーザが一定期間内に同じ曲を繰り返す回数の予測」に取り組む。その中でも、「アイテム選択の持続性」を表す個人的特徴を定義し、これに基づいてクラスタリングしたユーザごとに同じ曲を繰り返す回数を学習、ユーザごとに同じ曲を繰り返す回数を 2 値（増加または減少）で予測する手法を提案する。具体的には、同じ曲を繰り返す回数の時間経過による減衰を個人的特徴量として用い

<sup>1</sup> <https://www.amazon.co.jp/>

<sup>2</sup> <https://www.netflix.com/jp/>

<sup>3</sup> <https://japanese.alibaba.com/>

<sup>4</sup> <https://www.spotify.com/jp/>

ることを提案する。

本稿は、以下の構成を取る、2 節ではプレイリスト推薦の関連研究と視聴方法の特徴でユーザを分類する関連研究について述べる。3 節でユーザのクラスタリングと再生される曲の予測についての提案手法を説明し、4 節で評価実験の結果、及び結果の考察について述べる。最後に、5 節でまとめを行う。

## 2. 関連研究

本節では、プレイリスト推薦についての研究と、聴取傾向の違いに基づくユーザのクラスタリングについての研究について説明する。

### 2.1 プレイリスト推薦に関する研究

Nielsen が実施した 2017 年の調査<sup>5</sup>では、米国の Spotify ユーザの 58%が独自のプレイリストを作成し、32%が他のユーザと共有していることが示されている。MIDI4 が実施した 2016 年の調査<sup>6</sup>では、音楽ストリーミングサービス加入者の 55%が自分自身でプレイリストを作成していることが示されている。これらの研究は、音楽消費モードとしてプレイリストの重要性が高まっていることを示唆している。

ユーザエクスペリエンスの向上におけるプレイリストの重要性を考慮して、RecSys Challenge 2018[1]は、自動音楽プレイリスト補完タスクに焦点を当てている。本タスクの目的は、プレイリストの一部の断片的な情報からプレイリストの目的を推測し、目的に合わせたプレイリストを作成することである。具体的には、表 2.1 に示すプレイリストの断片的なデータが与えられたときに、元のプレイリストを補完する最大 500 トラ

表 2.1 RecSys Challenge における 10 種類のタスク ([1]をもとに作成)

条件番号	与えられるデータ
1	タイトルのみ、トラックなし
2	タイトルと最初の5トラック
3	最初の5トラック
4	タイトルと最初の10トラック
5	最初の10トラック
6	タイトルと最初の25トラック
7	タイトルと25のランダムトラック
8	タイトルと最初の100トラック
9	タイトルと100のランダムトラック
10	タイトルと最初のトラック

<sup>5</sup> <http://nielsen.com/us/en/insights/reports/2017/music-360-2017-highlights.html>.

<sup>6</sup> <https://midiareserach.com/blog/announcing-midias-state-of-the-streaming-nation-2-report>.

<sup>7</sup> <https://www.pandora.com>.

<sup>8</sup> <https://www.youtube.com>.

ックを推薦することであった。

タスクはメイントラック部門とクリエイティブトラック部門の 2 つに分かれていた。メイントラック部門では提供されたトレーニングセットの使用のみ許可されており、クリエイティブトラック部門では外部の公開ソースの使用も許可されていた。結果として、メイントラック部門で最高のパフォーマンスを発揮したチームは、0.2241 の Precision, 0.3946 の NDCG, 及び 1.784 回の平均クリック数を達成した。クリエイティブトラック部門では、R 精度 0.2233, NDG 0.3939, 平均クリック数 1.785 回が得られた。平均クリック回数とは、Spotify サービス内でのユーザ体験を評価する指標である。G をグラウンドトゥルース、R を推奨トラックのリストとしたとき、クリック数は

$$clicks = \left\lfloor \frac{\arg \min_i \{R_i: R_i \in G\} - 1}{10} \right\rfloor \quad (式 2.1)$$

と表される。

このチャレンジの中で、ほとんどのアプローチは、行列因数分解モデル、近傍ベースの協調フィルタリングモデル、基本的な情報検索技術、及びモデルのランク付け学習を含む、いくつかのよく知られた方法を用いている。

### 2.2 聴取傾向の特徴でユーザを分類する研究

推薦システムにおいて、ユーザによるフィードバックは重要であり、多くの研究が聴取体験を改善するために、ユーザの動作を理解しようとしてきた。ユーザの動作を理解することでユーザの目的が明らかとなり、目的に合わせた推薦を行うためである。

Jin Ha Lee ら[8]は、ユーザが音楽を聴く行動に関する情報を収集するために、Spotify や Pandora<sup>7</sup>, YouTube<sup>8</sup>ユーザを対象に商用音楽情報システムの使用に関する調査を 2015 年に実施した。その情報を定性的に分析して、7 種類のリスナーのペルソナを引き出した。

Mohsen Kamalzadeh ら[9]は、590 人の参加者を対象とした、音楽聴取体験におけるユーザコントロールとインタラクションに関する大規模な調査を 2012 年

に実施し、ユーザのライブラリにある曲の数と1日あたりのアクティブ/パッシブリスニングの平均時間を特徴量としてユーザをクラスタリングした。アクティブリスニングとはユーザ操作による再生であり、パッシブリスニングとは、ユーザが推薦されたものに操作を加えずに再生することである。この研究の目的は、ユーザの目的に合わせた推薦をするために、聴取傾向からユーザの目的を推定することであった。結果として、ユーザは5つのクラスタに分けられた。クラスタ間での違いを表2.2に示す。

Sooyeon Yoo ら[4]は、彼らの以前の研究 [8][9]で特定されたリスナーグループが、プレイレート分布と呼ばれる暗黙的なフィードバックを特徴量としてユーザのクラスタが同様に形成できるかどうかを検証した。プレイレートとは、曲の合計時間と比較した、ユーザが曲を実際に聴いた割合（再生時間）のことである。ユーザのクラスタリングは、Last.fm 1K-Dataset<sup>9</sup>を用いて行われた。結果として、以前の研究と比較して、ユーザ調査から見つかったリスナーグループの主な特徴の一部を反映した4つのクラスタが見つかった。プレイレートによるユーザのクラスタリングの結果を表2.3に示す。

### 2.3 まとめ

本節では、近年のプレイリスト推薦に関する既存研究と聴取傾向の特徴でユーザをクラスタリングする既存研究を紹介した。本研究の目的である「アイテム選択の持続性を最適化することによる、曲選択のコストが低減されたプレイリスト生成」において、既存研究の手法には、次のような課題点がある。ユーザに同じ曲を2度以上推薦することを想定していない点である。例えば、同じ曲を繰り返し聞くことを好むユーザとそうでないユーザがいたとする。既存手法では同じ曲は2度推薦されないため、前者のユーザは何度も同じ曲を選択し直さなくてはならない。この問題を解決するために、アイテム選択の持続性を予測することでユーザが曲を選択し直す回数を削減する手法が求められる。

## 3. 提案手法

本節では、同じ曲を繰り返す回数の時系列データを用いて、ユーザが同じ曲を繰り返す回数の増減を2値（増加または減少）で予測する手法について提案する。具体的には、「アイテム選択の持続性」を一定期間単位において同じ曲を繰り返す回数の増減と定義し、この

特徴量をもとにユーザをクラスタリングすることで、繰り返す回数の増減予測を行う。3.1項では、アイテム選択の持続性によるユーザクラスタリングの方法の説明を行う。3.2項では、同じ曲を繰り返す回数の増減予測と、繰り返す回数の予測精度比較について説明する。

### 3.1 アイテム選択の持続性によるユーザクラスタリングの方法

本稿では、「アイテム選択の持続性」を時間経過によって同じ曲を繰り返す回数の増減と定義する。アイテム選択の持続性が個人的特徴を持つと仮定すると、同じ曲を繰り返す回数の増加と減少傾向が似ているユーザグループがあると考えられる。この特徴でユーザをクラスタリングし、3.2項に示す方法で同じ曲を繰り返す回数を予測する。クラスタごとに予測を行った場合と、クラスタリングせず（全ユーザを1つのグループとして）予測を行った場合とを比較することで仮説が正しいか判断することができる。

まず、各ユーザの各曲の再生回数を週単位で集計した。ユーザ  $i$  が週  $j$  に曲  $t$  を再生した回数を  $N_{i(t,j)}$  とすると、再生回数の前週からの増減  $a_{i(t,j)}$  は、

$$a_{i(t,j)} = N_{i(t,j)} - N_{i(t,j-1)} \quad (\text{式 3.1})$$

と表される。 $j$  の範囲は当該曲を最初に聞いた週から最後に聞いた週とした。Last.fm 1K-Dataset に含まれる、ある特定のユーザ  $i$  が聞いた1つの曲  $t$  の  $N_{i(t,j)}$  を縦軸、 $j$  を横軸にプロットしたものを図3.1に示す。

あるユーザの再生回数上位100曲における  $a_{i(t,j)}$  の分布を図3.2に示す。先行研究[4]にならい、全ユーザ共通の10個のビンに分けて分布を表した。ビンは  $a$  の95%信頼区間である-50から50の範囲を等間隔で10分割した。また、表3.1に示すように、あるユーザに対しても  $a_{i(t,j)} = -1, 0, +1$  の場合がデータの多くを占めており、これはどのユーザに対しても同じであった。そのため、クラスタリングのためのデータの対象からは除いた。10個のビンの値をベクトルととらえ、ユーザをクラスタリングした。ユーザ  $i$  の10個のビンの値をそれぞれ  $b_{i1}, b_{i2}, \dots, b_{i10}$  とすると、ユーザの特徴量を表すベクトル  $v_i$  は

$$v_i = \{b_{i1}, \dots, b_{i10}\} \quad (\text{式 3.2})$$

と表される。これは、アイテム選択の持続性によってユーザをクラスタリングすることで、同じ曲の繰り返す回数増減の2値予測精度を向上できると考えたため

<sup>9</sup> <http://ocelma.net/MusicRecommendationDataset/lastfm-1K.html>

である.

表 2.2 ユーザコントロールとインタラクションの調査

Type Nickname	Number of Participants	Description	Active Hours Median	Passive Hours Median	Collection Size Median (songs)
Majority	472	The most dense area of the active/passive/collection sizespace. These participants' responses are closer to the medians of all participants, and thus, they reflect the whole population.	1	3	3,600
Actives	23	Mildly higher than Majority active hours and collection size, but very low passive hours.	2	1	15,300
Collectors	26	Similar to Majority active hours, with mildly higher passive hours; but much larger collections.	1	4	55,100
Passives	20	Similar to Majority active hours and collection sizes, but very high passive hours.	1	7	4,200
Musicals	31	These participants have very high active hours along with relatively high passive hours, but similar to Majority collection sizes.	3	5	6,200

表 2.3 プレイレートによるユーザクラスタリング ([4]を元にトレース)

Cluster (of users)	Listener group	Properties
1(526)	Casuals	Music plays a welcomed role, but other things are far more important
	Guided Listeners	Just want to hear something playing
	Passives	Very high passive hours
	Addicts	May listen to the same song repeatedly
2(288)	Enthusiastics	Music is a key part of life but is also balanced by other interests
	Active Curators	Most actively engaged with music services
	Actives	High active hours, very low passive hours
3(30)	Music Epicureans	Great amount of time is spent hunting for new music
	Wanderers	Enjoys serendipitous music discovery
		Tend to listen to music from a wide variety of music genres
4(39)	Music Epicureans	Self-directed in listening to music

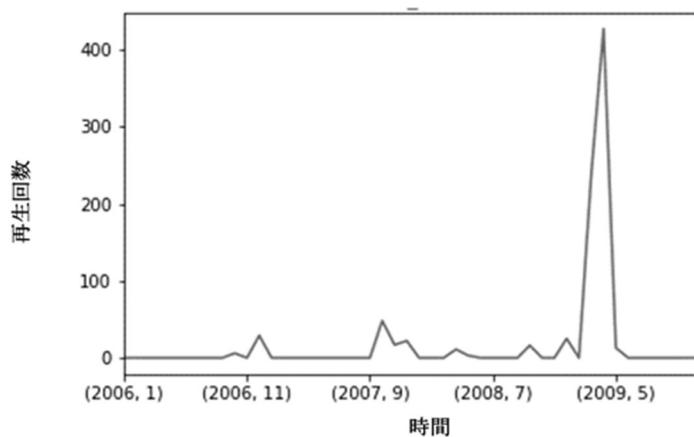


図 3.1 ある特定のユーザ  $i$  が聞いた 1 つの曲  $t$  の再生回数の時系列推移

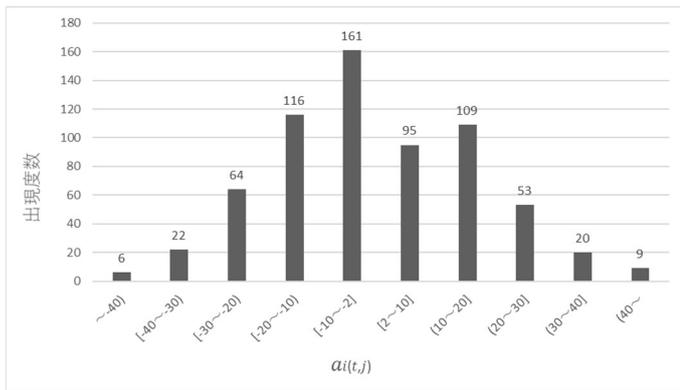


図 3.2 あるユーザの再生回数上位 100 曲における増減値の分布

表3.1 全ユーザの再生回数増減値の分布

ピンの範囲	出現回数が占める割合(%)
(40~50]	0.30
(30~40]	0.40
(20~30]	2.30
(10~20]	4.00
[2~10]	5.10
1	14.10
0	44.40
-1	16.20
[-10~-2]	5.00
[-20~-10)	4.30
[-30~-20)	3.00
[-40~-30)	0.50
[-50~-40)	0.40

ユーザのクラスタリングには  $k$  平均法を用いた。データの数  $n$ 、クラスタの数を  $k$ 、各クラスタの中心を  $V_j$  ( $j=1, \dots, k$ ) としたとき、式を式 3.2 に示す。

$$\operatorname{argmin}_{V_1, \dots, V_k} \sum_{i=1}^n \min_j \|v_i - V_j\|^2 \quad (\text{式 3.3})$$

アイテム選択の持続性によってクラスタリングされたクラスタごとに学習と予測を行う。

### 3.2 同一曲を繰り返す回数の予測方法

同じ曲を繰り返す回数の増減がユーザの個人的特徴であると仮定すると、過去の聴取傾向（別の曲に対する再生回数の増減傾向）から当該ユーザの繰り返すを予測することが可能となる。本研究では、 $a_{i(t,j)}$  を予測する初期段階として、 $a_{i(t,i)}$  を正負の二値で予測する

方法を提案する。

$a_{i(t,j)}$  の正負を予測するにあたって、入力に予測したい週  $j$  の直前  $k$  週間の再生回数の増減とし、図 3.3 に示すように  $k=1 \sim 15$  の範囲で最も精度が高かった  $k=10$  として実験を行った。入力の式を式 3.3 に示す。

$$\text{input} = [a_{i(t,j-10)}, a_{i(t,j-9)}, \dots, a_{i(t,j-1)}] \quad (\text{式 3.4})$$

この時  $j$  は、Last.fm 1K-Dataset の中で、当該曲  $t$  の  $N_{i(t,j)}$  が最大となった週の前後 10 週の中からランダムに選択した。これは、予測する週の  $N_{i(t,j)}$  が 0 になる回数を減らすためである。

予測モデルは、表 3.2 に示す手法で行った。そして、全ユーザのデータを用いて  $a_{i(t,j)}$  の 2 値予測を行った結果、最も精度の高かった Random Forest を採用した。

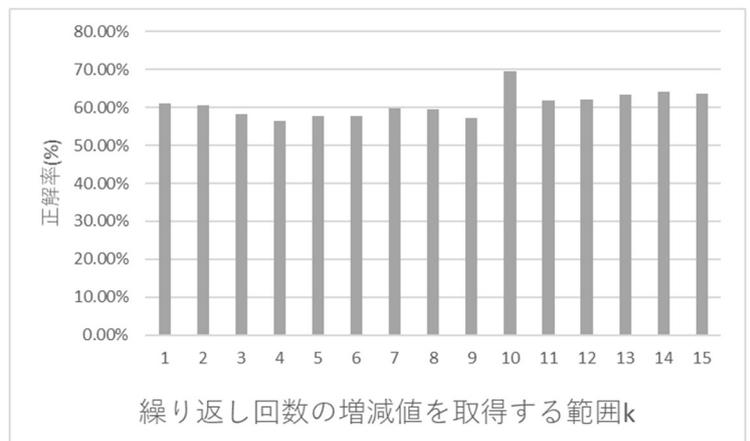


図 3.3  $k$  の値と 2 値予測の正解率

表3.2 アルゴリズムの比較

アルゴリズム	正解率(%)
Random Forest	69.76
Nearest Neighbors	65.60
Decision Tree	65.67
RBF SVM	62.94
AdaBoost	60.48
Logistic Regression	59.72
Linear SVM	59.35
Naive Bayes	55.55
Polynomial SVM	51.26
Sigmoid SVM	49.58

## 4. 評価実験

本節では、使用したデータセット、分類問題の精度の評価指標、ユーザのクラスタリングの結果、ユーザをクラスタリングする前後での結果の比較について述べる。

表 4.1 Last.fm 1K-Dataset における  
リスニングデータの一部

user id	Timestamp	Artist id	Artist name	Track id	Track name
1	2008/8/13 14:19	5	Artful Dodger	6	What You Ganna Do?
1	2006/8/13 14:17	3	Tommy	13	Mission Flats

#### 4.1 使用したデータセット

評価実験では, Norman Casagrande による Last.fm 1K-Dataset をデータセットとして用いた. Last.fm 1K-Dataset は 992 人のユーザが 2006 年から 2009 年までに再生した曲の再生履歴のデータセットである. データセットの一部を表 4.1 に示す. なお, 本データセットにおける再生回数の合計は 19,150,868 回である. このうち, ユーザごとに再生回数の上位 100 曲をクラスタリングと予測に用いた. 検証には 5 分割交差検証を用いた.

#### 4.2 評価指標

本実験では増減の分類の正解率を評価指標とした. 以下に式を示す.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (\text{式 4.1})$$

#### 4.3 k 平均法によるユーザクラスタリングの結果

k 平均法を用いて, 3.1 項で述べた「傾きの分布」のベクトルをもとにユーザをクラスタリングした結果を表 4.2 に示す. 表 4.2 は 2~9 グループにクラスタリングした時の各グループの人数を表している.

#### 4.4 同一曲の再生回数増減の予測結果

表 3.1 に示した結果から本実験では提案手法, ベースラインのどちらに対しても Random Forest を採用することとした. 表 4.3, 図 4.1 に提案手法による繰り返し回数予測の結果とベースラインの比較を示す. ベースラインは, 予測する週の直前 10 週間の繰り返し回数増減値の正負を入力として予測した手法の結果とした.

表 4.3, 図 4.1 から正負のみを入力にするのではなく再生回数の変化量が重要であることがわかる.

また, クラスタ数と予測精度の比較結果を示す. ベースラインはクラスタリングをせずに予測を行ったものとした.

表 4.4, 図 4.2 に示すように, クラスタ数によらず,

クラスタリングしたほうが予測の精度が向上することが分かった. つまり, アイテム選択の持続性は個人的特徴に依存することがわかった. また 2~9 グループのクラスタリングの中では, 7 クラスタにクラスタリングした時が最も精度が高くなった.

### 5. おわりに

本論文では, 音楽推薦システムにおいて「アイテム選択の持続性」がパーソナライズされていないという問題を解決する手法を提案した. 具体的には, 各ユーザが週単位で同じ曲を繰り返した回数増減によって, 次週の再生回数増減を予測する 2 値分類モデルの学習を行った. 予測する週の直前 10 週間の繰り返し回数増減値の正負を入力として予測したベースラインと比較して, 提案手法は 6.62% 精度が向上した.

また, 「アイテム選択の持続性は個人的特徴である」という仮説を検証するために, 同じ曲を繰り返す回数増減から傾きの分布を抽出し, ユーザをクラスタリングし, クラスタごと学習した予測モデルを用いて, 繰り返し回数増減を 2 値で予測した. そして, クラスタリングをした場合としなかった場合を比較することで, 結果として, ユーザを 7 つのクラスタにクラスタリングして学習, 予測を行った場合に, 最も高い 77.17% の予測精度を達成し, ユーザをクラスタリングせずにすべてのユーザで学習, 予測を行った場合と比較して 7.42% 向上した.

本手法を使用した今後の研究としては 1) 繰り返し回数の具体的な数値を予測すること, 2) 増減の絶対値ではなく増減率をもとに予測を行うこと, 等を検討している.

表 4.2 各クラスターのユーザ数

クラスター数	1	2	3	4	5	6	7	8	9
各クラスターのユーザ数	992	469	336	160	150	97	97	86	51
		523	313	249	167	165	150	135	134
			343	319	188	166	140	137	137
				264	237	226	164	145	111
					250	174	163	117	103
						164	162	105	123
							116	106	106
								161	161
									66

表 4.3 ベースラインと提案手法の比較

手法	正解率(%)
直前10週間の繰り返し回数増減値(正負のみ) (ベースライン)	63.14
直前10週間の繰り返し回数増減値 (提案手法)	69.76

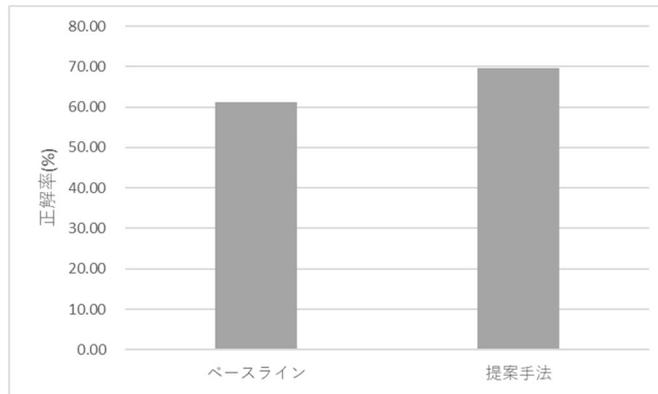


図 4.1 ベースラインと提案手法の比較

表 4.4 クラスタ数による正解率の比較

クラスター数	1(クラスタリングなし)	2	3	4	5	6	7	8	9
正解率(%)	69.76	73.19	73.97	74.69	74.80	76.51	77.17	75.14	75.65

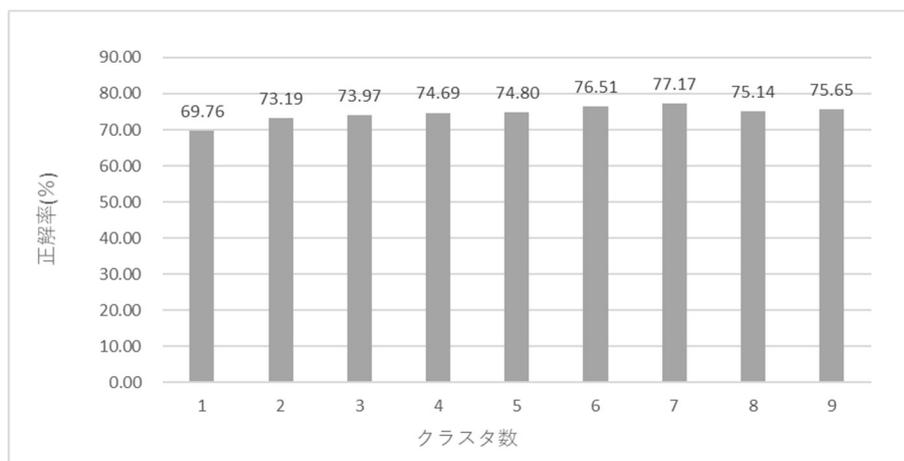


図 4.2 クラスタ数による同一曲の再生回数増減の予測正解率の比較

## 参 考 文 献

- [1] Hamed Zamani, Markus Schedl, Paul Lamere, and Ching-Wei Chen. 2019. An Analysis of Approaches Taken in the ACM RecSys Challenge 2018 for Automatic Music Playlist Continuation. *ACM Trans. Intell. Syst. Technol.* Vol.10, No.5, Article57 (September 2019).
- [2] Xinxi Wang, David Rosenblum, and Ye Wang. 2012. Context-aware mobile music recommendation for daily activities. In *Proceedings of the 20th ACM international conference on Multimedia (MM '12)*. Association for Computing Machinery, New York, NY, USA, pp99–108.
- [3] Markus Schedl. 2013. Ameliorating Music Recommendation: Integrating Music Content, Music Context, and User Context for Improved Music Retrieval and Recommendation. In *Proceedings of International Conference on Advances in Mobile Computing & Multimedia (MoMM '13)*. Association for Computing Machinery, New York, NY, USA, pp3–9.
- [4] Eva Zangerle, Martin Pichl, and Markus Schedl. 2018. Culture-Aware Music Recommendation. In *Proceedings of the 26th Conference on User Modeling, Adaptation and Personalization (UMAP '18)*. Association for Computing Machinery, New York, NY, USA, pp357–358.
- [5] Flavian Vasile, Elena Smirnova, and Alexis Conneau. 2016. Meta-Prod2Vec: Product Embeddings Using Side-Information for Recommendation. In *Proceedings of the 10th ACM Conference on Recommender Systems (RecSys '16)*. Association for Computing Machinery, New York, NY, USA, pp225–232.
- [6] Noveen Sachdeva, Kartik Gupta, and Vikram Pudi. 2018. Attentive neural architecture incorporating song features for music recommendation. In *Proceedings of the 12th ACM Conference on Recommender Systems (RecSys '18)*. Association for Computing Machinery, New York, NY, USA, pp417–421.
- [7] Daye Kwon and Woohun Lee. 2018. Artifact Mixtape: Curating Music in Personal Tangible Artifacts. In *Proceedings of the 2018 ACM Conference Companion Publication on Designing Interactive Systems (DIS '18 Companion)*. Association for Computing Machinery, New York, NY, USA, pp265–270.
- [8] Jin Ha Lee and Rachel Price. 2015. Understanding Users of Commercial Music Services through Personas: Design Implications. In *Proceedings of the 16th International Conference on Music Information Retrieval (ISMIR)*. pp476–482.
- [9] Mohsen Kamalzadeh, Dominikus Baur, and Torsten Möller. 2016. Listen or interact? A Large-scale survey on music listening and management behaviours. *Journal of New Music Research* 45, 1 (2016), pp42–67.