

# 楽曲聴取行動系列の階層化による 聴取傾向変化の検出と行動分析

高野 雅典<sup>1,a)</sup> 鳥海 不二夫<sup>2</sup> 和田 計也<sup>1</sup> 福田 一郎<sup>1</sup>

概要：人は音楽聴取行動において、本来の趣味趣向に加え、気分や状況によって聴取する音楽を変える。その聴取傾向は大きな変化から小さな変化までありうる。サブスクリプション型音楽配信サービスにおいてユーザの聴取傾向を定量的に評価することは、ユーザの行動理解や、機能改善・推薦アルゴリズムのユーザ行動に与える影響の評価に有効である。そこで本研究では、ユーザの楽曲聴取行動系列を階層的に分析する手法を提案する。この手法によって、いつ・どの機能・どのような音楽を利用している時に、どのように聴取音楽のタイプが変わるかを複数の粒度で知ることができる。提案手法は楽曲聴取の系列データについて階層的に隠れマルコフモデルを適用し、聴取行動の大きな変化と小さな変化を検出する。そして検出した楽曲聴取傾向の変化を利用してユーザの行動を分析する。

キーワード：ユーザプロファイリング、音楽聴取行動、隠れマルコフモデル

## Hierarchical Understanding of User Behavior on Music Streaming Service AWA

MASANORI TAKANO<sup>1,a)</sup> FUJIO TORIUMI<sup>2</sup> KAZUYA WADA<sup>1</sup> ICHIRO FUKUDA<sup>1</sup>

### 1. はじめに

サブスクリプション型音楽配信アプリケーションは楽曲単位の購入ではなく、1ヶ月単位の定額契約で数千万曲以上の楽曲聴取を提供する。したがって従来のビジネスモデルに比べて、ユーザは莫大な音楽に容易にアクセスできるようになった。ユーザに膨大な選択肢がある中で快適な楽曲聴取体験を提供するためには、ユーザの聴取行動を知ることが重要である [1]。

ユーザの楽曲選択には様々な要素が影響すると考えられる。同じユーザでも本来持つ趣味趣向に加えて様々な外因・内因によって、楽曲の聴取傾向を変えると考えられる。例えば、いつもはジャズを聴いているが、昨日のテレビ番組の影響で J-POP を聴くなどである。本研究はこの“聴取傾向の変更”の検出に焦点を当てる。どのぐらいの頻度

でいつ起きるのか？アプリケーションのどの機能に起因して起きるのか？聴取傾向の変更はいいことなのか？について知ることが目的である。例えば、これによって推薦アルゴリズムの発見性・多様性の評価 [2], [3] が期待できる。音楽聴取にクラウドサービスやサブスクリプション型のサービスを利用するユーザはデータをサービスサイドが持つことによって、未知の好みの音楽に出会うことを期待しており [4]、適切なタイミングで適切な楽曲やアーティストを推薦することは重要である。

そこで本研究はサブスクリプション型音楽配信アプリケーション“AWA<sup>\*1</sup>”におけるユーザの楽曲聴取ログから、そのユーザの聴取傾向とその変化を検出するモデルを提案する。一般に人の行動傾向は様々な粒度で解釈・考察することができる。楽曲聴取行動であれば、1つの楽曲聴取が最も詳細な粒度であり、最も大きな粒度は邦楽や洋楽などであろう。したがって人の行動傾向の理解には階層的にモ

<sup>1</sup> 株式会社サイバーエージェント

<sup>2</sup> 東京大学 大学院工学系研究科

<sup>a)</sup> takano\_masanori@cyberagent.co.jp

<sup>\*1</sup> 株式会社 AWA が運営するサブスクリプション型音楽配信サービス (<https://awa.fm/>)。




図 1 モデル概要

デル化が有効である [5], [6].

本研究では隠れマルコフモデル (HMM) [7] を使ってユーザの聴取傾向とその変化をモデル化する。複数の粒度を階層的にモデル化するために、HMM を階層的に作成する (図 1)。構築したモデルを用いて、聴取傾向の変化について分析する。

## 2. データと手法

本研究では HMM を階層的に用いることによってユーザの聴取傾向を階層的にモデル化した (図 1)。系列データとして各ユーザ  $i$  の各時間  $h$  に最も聴いた \*2 アーティストのリスト  $\mathbf{x}_i$  を用いた ( $h \in \{0, 1, \dots, 23\}$ ,  $\mathbf{x}_i = \{x_{ih}\}$ )。例えば、あるユーザの系列は “[{5/11-10: 西野カナ}, {5/11-11: 加藤ミリヤ}, {5/11-17: KISS}, {5/13-11: QUEEN}, {5/13-24, AAA}, …]” である (1 つめの項目は 5 月 11 日 10 時台に西野カナ氏の楽曲を最も聴いたことを表す)。利用していない時間については系列データに含まない。

最初に第 1 階層の聴取傾向をモデル化した。学習に利用する系列データは前述の  $\mathbf{x}_i$  である。状態数は 2 から 15 の内、最も AIC [8] が小さいものを採用した。ユーザ  $i$  の系列  $x_{ih}$  に対応する第 1 階層の状態を  $z_{ih}$  と書く。

次に第 1 階層の結果を用いて、第 2 階層の聴取傾向をモデル化した。学習に利用する系列データはユーザ  $i$  の状態  $z_{ih}$  が同じ状態を維持し続けた間を 1 つの系列とした。すなわち、あるユーザの第 1 階層の状態の推移が  $\{1, 1, 1, 2, 2, 1, 1\}$  であった場合、状態 1 に対する系列データが 2 つ ( $\{1, 1, 1\}$ ,  $\{1, 1\}$ )、状態 2 が 1 つ ( $\{2, 2\}$ ) が得られることになる。ユーザ  $i$  の  $j$  番目の状態  $z$  に対する第 2 階層の状態を  $z'_{i,z_j}$  と書く。こちらも第 1 階層と同様に AIC で状態数を決定する。

本手法は再帰的に適用することでアーティストと状態が 1 対 1 に対応するまで階層を深くすることができる。本研究では階層を 2 とした。HMM の学習には Baum-Welch アルゴリズム、推定には Viterbi アルゴリズムを用いた。モデルの作成に使用したデータは月額課金登録ユーザの内、系列長が 70 以上であるユーザからランダムサンプリングした後、その中から典型的なユーザとして系列長が 25%ile

から 75%ile の範囲のユーザの系列データを用いた (ユーザ数: 2,186)。期間は 2017/03/01 から 2017/05/10 の 71 日間である。

## 3. 結果

### 3.1 モデルの学習結果

前節の方法でモデルを構築した結果、第 1 階層は 11 状態、第 2 階層は各第 1 階層の状態に対してそれぞれ 4, 5, 7, 7, 6, 8, 8, 10, 8, 8, 7 個の状態の HMM が得られた。第 1 階層の各状態の代表的なアーティストを表 1 に示す。

### 3.2 基本的な聴取傾向

このモデルを用いユーザの聴取傾向を分析する。分析で使用したデータは、系列長が 2 以上である月額課金登録ユーザからランダムサンプリングをしたユーザの系列データである (対象ユーザ数: 19,929)。期間は 2017/04/01 から 2017/05/21 の 50 日間である。

ユーザの聴取傾向の推移の典型例を図 2 を示す。聴取傾向の変化が検出されたこと、それがユーザの聴取傾向の違いを表現可能であることがわかる。聴取傾向推移率の頻度分布を図 3 に示す。状態をほとんど変えないユーザとある程度変えるユーザに 2 分化していたことがわかる。

### 3.3 曜日・時間による聴取傾向への影響

ではユーザはいつ聴取傾向を変化させるのか? それについて知るために図 4 に各曜日の各時間ごとの状態推移回数の平均値を示す。同図から平日の午前 7-9 時には聴取傾向の変化が発生しやすく、平日の深夜には発生しにくいことがわかる。これは通勤・通学時には多様な楽曲を聴く傾向にあること、または、朝には昨日の聴取傾向とは異なる傾向があるということを示す。休日は基本的には平日と類似しているがその傾向は弱い。これは平日は多くのユーザが通学・通勤しているのに対し、休日はライフスタイルが多様であるため傾向が弱まったと考えられる。


### 3.4 楽曲選択機能による聴取傾向への影響

ではどのようにして聴取傾向の変化は発生しているのか? AWA を含めサブスクリプション型音楽配信サービス


\*2 楽曲を最後まで再生した場合、聴いたと定義した。

表 1 各状態の代表的なアーティスト

状態					
1	Relax $\alpha$ Wave	超特急	Madonna	Coldplay	矢沢永吉
2	Zedd	Ed Sheeran	Avicii	Flo Rida	Rihanna
3	Bruno Mars	Justin Bieber	Ariana Grande	Ed Sheeran	Maroon 5
4	ちゃんみな	CREAM	AK-69	ANARCHY	KREVA
5	BIGBANG	Twice	SHINee	防弾少年団	少女時代
6	Ms.OOJA	globe	Superfly	クリス・ハート	lecca
7	浜崎 あゆみ	加藤 ミリヤ	倅田來未	JUJU	BENI
8	清水 翔太	ケツメイシ	GReeeeN	平井 大	西野 カナ
9	三代目 J Soul Brothers from EXILE TRIBE	西野 カナ	Flower	EXILE	EXILE THE SECOND
10	AAA	Acid Black Cherry	AKB48	Da-iCE	Aimer
11	ONE OK ROCK	乃木坂 46	UVERworld	欅坂 46	[Alexandros]




(a) 安定した聴取傾向のユーザ



(b) 頻繁に変化する聴取傾向のユーザ

図 2 聴取傾向推移の典型例。縦軸は状態を表す(第 1 階層の状態-第 2 階層の状態)。



(a) 第 1 階層

(b) 第 2 階層

図 3 状態変化率(系列長に対する状態推移頻度の比率)の分布。

では、複数の楽曲選択機能を提供する。表 2 に機能ごとの聴取傾向変化数の平均値を示した。各系列項目にその項目で最もユーザが利用した機能を紐付け、その項目の状態

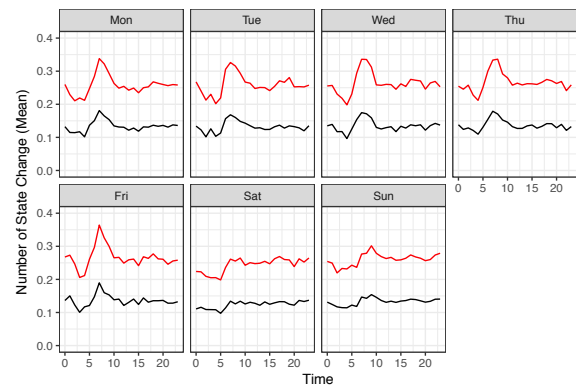


図 4 各曜日の日時間変化(黒: 第 1 階層, 赤: 第 2 階層)。集計範囲は 2017/04 である。5 月は祝日を多く含むため除外した。

表 2 再生機能ごとの聴取傾向変化数。全系列データ中に 2000 回以上登場した機能のみ示している。

Function	Layer 1	Layer 2
Offline (Track)	5.17	10.83
My Playlist	4.41	8.88
Favorite (Track)	3.94	8.37
Favorite (Playlist)	2.18	4.09
Recommend	1.70	3.46
Favorite (Album)	1.47	2.66
Favorite (Artist)	1.13	2.10
Genre Rankings	1.04	1.82
Featured Playlists	0.78	1.30
Search (Artist)	0.74	1.31
Artist's Album	0.59	1.06
Search (Playlist)	0.51	0.89
Search (Album)	0.44	0.77
Track Information	0.42	0.78
Search (Track)	0.37	0.65
New Arrivals	0.36	0.66
Artist Information	0.35	0.63
Related Artists	0.31	0.62
Related Playlists	0.19	0.37

と 1 つ前の項目の状態が異なれば、その機能によって状態が変化したとした。同表から第 1 階層・第 2 階層共に、

オフラインライブラリからの再生 (Offline (Track)), 自作プレイリスト (My Playlist), ブックマーク (Favorite) によって聴取傾向の変化が発生しやすかったことがわかる。これらはユーザが“自分自身で作成したリストから楽曲やプレイリストなどを選択し聴取する”機能である。推薦 (Recommend) は中間よりやや聴取傾向を変化させやすい傾向にあると言える。一方で検索 (Search) や関連項目<sup>\*3</sup>といったユーザ自身が未知の楽曲・アーティスト・プレイリストを探索する行動によっては、聴取傾向の変化は発生しにくかった。また、第1階層・第2階層の変化しやすさには強い相関があり、どちらか一方のみを変化させやすい機能は無かった。以上からユーザの聴取傾向変化は、ユーザが既知の楽曲・プレイリストの中から能動的に今まで聴いていたものとは異なる傾向のものを選択することに起因していると言える。また、現状のAWAの機能には聴取傾向の変化の大小どちらかのみが発生しやすくなるような機能は存在しないと言える。

### 3.5 聴取傾向変化の利用頻度への影響

聴取傾向の変化はユーザにどのような影響をおよぼすのか？ここでは次の7日間の楽曲聴取頻度  $y$  に焦点を当て、次の一般化線形モデル (GLM) を考える。

$$y \sim B(n, p) \quad (1)$$

$$\text{logit}(p) = \beta_1 m + \beta_2 s + \beta_3 s'$$

ここで、 $B(n, p)$  は試行数  $n$ , 確率  $p$  の二項分布,  $m$  は系列長,  $s$  は第1階層の聴取傾向変化数,  $s'$  は第2階層の聴取傾向の変化数である。 $m$  はサービスの利用頻度を調整するための共変量である。

表3に式1の分析結果を示す。第1階層の変化頻度  $s$  は利用頻度を減らした一方で、第2階層の変化頻度  $s'$  は利用頻度を増やしたことが分かる。すなわち大きな聴取傾向の変化ではなく、小さな聴取傾向の変化をユーザに提供することがユーザの利用頻度を高めることに重要であることが示唆される。

では多様な楽曲を聴取することユーザにとどのような影響をあたえるのか？前述のモデルと同様に次の7日間の楽曲聴取頻度  $y$  に焦点を当て、次のGLMを考える。

$$y \sim B(n, p) \quad (2)$$

$$\text{logit}(p) = \beta_1 m + \beta_2 c + \beta_3 c'$$

ここで  $c$  は第1階層の期間内に経験した状態の数,  $c'$  は第2階層の期間内に経験した状態の数である。それ以外は式1と同様である。

表4に式2の分析結果を示す。第1階層の経験状態数  $c$

<sup>\*3</sup> AWAでは楽曲・アーティスト・プレイリストの詳細画面から関連したアーティスト・プレイリストの画面に遷移することができる。

は有意ではなかった。一方で、第2階層の経験状態数  $c'$  は利用頻度を増やしたことが分かる。すなわちある程度類似した範囲の楽曲群で様々な楽曲を聴取することがユーザの利用頻度を高めたと言える。

## 4. まとめ

本研究ではユーザの聴取傾向の変化について分析するために、HMMを階層的に構築するモデルを提案した。その結果、複数の粒度でユーザの聴取傾向の変化を検出することができた。

検出した結果を用いて、ユーザ行動を分析した。その結果、ユーザは通学・通勤時に楽曲聴取傾向を変化させがちであること、深夜には楽曲聴取傾向を変化させにくいことがわかった。したがって、平日の午前7-9時に普段とは異なった楽曲やアーティストを推薦した場合、ユーザはその楽曲を受け入れやすいことが示唆される。そのためユーザの音楽との出会いを促進するには、この時間帯に施策を実行することが有効であろう。

ただし、聴取傾向変化とユーザの次週の利用頻度の分析によって、楽曲聴取傾向の大きな変化（例えば邦楽女性歌手から洋楽への変化など）はユーザの利用頻度を下げ、小さな変化はユーザの利用頻度を上げることが示された。したがって小さな音楽の出会いを促進し続けることでユーザの満足度を上げ、継続的な利用を促せると考えられる。

これは小さな聴取傾向の変化を発生させやすくする推薦アルゴリズムが重要であることを示唆する。本研究の分析では小さな変化だけを発生させやすい楽曲選択機能は存在しなかった。一般的な楽曲選択機能はブックマークなどの自作のリストや検索などの探索機能である。それらはシンプルで直感的にもわかりやすい機能であるため、“聴取傾向の小さな変化を発生させやすくする”という仕組みを組み込むことは難しい。そのような細やかな工夫が可能なのは推薦機能であろう。したがって聴取傾向の変化を目的とした推薦アルゴリズムの導入が重要である。

本手法は推薦アルゴリズムの比較・評価にも用いることができる。推薦アルゴリズムにとって「ユーザに新たな情報を提供できるか？」という発見性・多様性の評価は重用である [2], [3]。提案手法を用いることで、推薦アルゴリズムのユーザの聴取傾向をどのように変化させやすいか（ユーザに音楽の出会いを提供できるか）を評価できる。それは推薦アルゴリズムの選択や改善の際に有効な指標になるであろう。

## 参考文献

- [1] Zhang, B., Kreitz, G., Isaksson, M., Ubillos, J., Urdaneta, G., Pouwelse, J. A. and Epema, D.: Understanding user behavior in Spotify, *2013 Proceedings IEEE INFOCOM*, IEEE, pp. 220–224, DOI: 10.1109/INFOCOM.2013.6566767 (2013).

表 3 式 1 モデルによる分析結果

Explanation Value	Coefficient	Standard Error	t-value	p-value
$m$	0.0147455	0.0001773	83.157	Less than $2.0 \times 10^{-16}$
$s$	-0.0049439	0.0011958	-4.134	$3.56 \times 10^{-5}$
$s'$	0.0045396	0.0014170	3.204	$1.36 \times 10^{-3}$
Intercept	-1.0551538	0.0111014	-95.047	Less than $2.0 \times 10^{-16}$

表 4 式 2 モデルによる分析結果

Explanation Value	Coefficient	Standard Error	t-value	p-value
$n$	0.0141416	0.0001451	97.438	Less than $2.0 \times 10^{-16}$
$c$	0.0052646	0.0067718	0.777	$4.36 \times 10^{-1}$
$c'$	0.0071810	0.0025364	2.831	$4.64 \times 10^{-3}$
Intercept	-1.0903282	0.0146133	-74.612	Less than $2.0 \times 10^{-16}$

- [2] Ziegler, C.-N., McNee, S. M., Konstan, J. A. and Lausen, G.: Improving recommendation lists through topic diversification, *Proceedings of the 14th international conference on World Wide Web - WWW '05*, New York, New York, USA, ACM Press, p. 22, DOI: 10.1145/1060745.1060754 (2005).
- [3] Hurley, N. J.: Towards diverse recommendation, *RecSys Workshop: Novelty and Diversity in Recommender Systems (Keynote)* (2011).
- [4] Lee, J. H., Kim, Y.-S. and Hubbles, C.: A Look at the cloud from both sides now: an analysis of cloud music service usage, *Proceedings of the 17th International Society for Music Information Retrieval Conference*, pp. 299–305, (2016).
- [5] Kawazu, H., Toriumi, F., Takano, M., Wada, K. and Fukuda, I.: Analytical method of web user behavior using Hidden Markov Model, *2016 IEEE International Conference on Big Data (Big Data)*, IEEE, pp. 2518–2524, DOI: 10.1109/BigData.2016.7840891 (2016).
- [6] 垣内 弘太, 鳥海 不二夫, 高野 雅典, 和田 計也, 福田 一郎: 潜在状態を用いたコミュニティサービスの分析, 人工知能学会全国大会, 4N2-OS-01b-3in2 (2017).
- [7] Rabiner, L.: A tutorial on hidden Markov models and selected applications in speech recognition, *Proceedings of the IEEE*, Vol. 77, No. 2, pp. 257–286 (online), DOI: 10.1109/5.18626 (1989).
- [8] Witowski, V. and Foraita, D. R.: HMMpa: Analysing accelerometer data using hidden Markov models, *R package version 1.0* (2014).