

日常行動に沿った選曲と音響特徴量の関係の可視化

黒子なるみ^{1)*} 大矢隼士²⁾ 伊藤貴之¹⁾ (正会員)

1) お茶の水女子大学 2) Septeni Japan 株式会社

*現在株式会社 NTT ドコモ所属

Visualization of the Relationship between Music Selection and Acoustic Features according to Daily Activities

Narumi Kuroko¹⁾ Hayato Ohya²⁾ Takayuki Itoh¹⁾(Member)

1) Ochanomizu University 2) Septeni Japan, Inc

1) {g1520511, itot} @ is.ocha.ac.jp, 2) hayato.oya @ septeni.co.jp

アブストラクト

一般的にユーザが鑑賞する楽曲を選曲する際に、その時の行動が判断に影響を与えることはよく知られている。我々はこの事実にもとづき、日常生活の中で繰り返される習慣的動作において鑑賞したい楽曲の音響特徴量を音楽推薦に用いる手法を検討している。ここで、どのような行動中にどのような音響特徴量を有する楽曲が好まれるのかを深く検証することで、日常行動と楽曲の相関に対する理解を深め、音楽推薦の満足度向上につなげられると考えられる。そこで我々は、日常的な行動をシチュエーションごとに分けて、そのシチュエーションにおいて聴きたいと思う楽曲の相関を検証するための可視化を試みた。本論文では、日常的な各シチュエーションでの被験者群の選曲結果とその音響特徴量を検証するためのいくつかの可視化手法、およびその可視化結果について紹介する。

Abstract

When people choose songs that they want to listen to, it is well-known that their behaviors of that time have an influence on their choices. Based on this nature, we developed a method for music recommendation that selects songs based on the acoustic features of songs which is listened in daily activities. We expect that we can understand the correlation between activities and songs, examining what kind of acoustic features of a song tend to be chosen by examinees who are in a given condition. And we also expect that the music recommendation system gives users higher satisfaction. In this paper, we present a visualization method with results for verifying the correlation between activities and acoustic features.

1. はじめに

近年では主に海外主要国において、ストリーミングサービスが音楽鑑賞の主たるメディアとなってきた。これらの環境の変化により、人々はインターネット上で何百万もの楽曲を、場所に左右されずに聴くことができるようになった。しかし、このように視聴可能な楽曲の選択肢が増えるにつれて、鑑賞者は情報過負荷状態となり、単純な決定方略が取られやすくなってしまふ[1]。そこで我々は、鑑賞者の好みに合わせた楽曲を自動選曲する音楽推薦システムの研究に従事している。

Songらの音楽推薦に関する広範なサーベイ[2]によると、音楽推薦手法はメタデータ、音響データ、協調フィルタリング、文章、感情、ハイブリットの6種類に分類される。これらに加えて最近では、日時や場所[3]、行動[4]など、鑑賞者個人に関する複数の要因が選曲に影響する傾向が注目されている。これにとともに、音響データと鑑賞者個人の要因を同時に考慮した音楽推薦システムに関しても、これまでいくつか開発されてきた。Wangら[4]は、時間帯や位置情報から鑑賞者の日常行動を推測し、その行動に適した楽曲を推薦するシステムを開発した。Åmanら[5]は、スマートフォンに搭載されたセンサによって検出できる情報（鑑賞者の位置情報、移動のペース、マイクからの音声など）をもとに、鑑賞者がどんな日常行動をしているかを検出し、それに適した楽曲を推薦するシステムを開発した。我々もこれらの研究と同様に、鑑賞者個人の日常行動と音響特徴量の関係は音楽推薦の満足度を向上する重要な知見であると考えられる。

情報推薦システムにおいてアイテムの推薦時にその推薦理由を提示することは、推薦アイテムに対して説明性を持たせることにつながる[6]。推薦システムの説明性を向上することで、音楽鑑賞者とシステム事業者・権利者の双方に対して、システム全体に対する信頼度や満足度の向上を期待できる。音楽推薦システムにおいても同様に、楽曲推薦の根拠を提示することが、説明性の高い音楽推薦システムの確立につながると思われる。

本論文では、楽曲推薦における重要な知見と考えられる日常行動と音響特徴量の関係を可視化するシステムを提案する。提案手法は以下の2つの要件を可視化によって満たすものである。

[要件 1: 大局的傾向の発見] 各々の日常行動、各々の音響特徴量に対して、鑑賞者群と楽曲群の大局的な相関を可視化することで、データ全体を通して特定の日常行動の中でどの音響特徴量が選曲に大きく寄与するかについて大局的な傾向を表現する。

[要件 2: 局所的特徴の発見] 特定の鑑賞者群によって選ばれる特定の楽曲群を可視化することで、特定の日常行動の中で特定の鑑賞者群にどのような特定の選曲が見られるかといった局所的な特徴を表現する。

これらの要件を満たすために本研究では、Cockburnら[7]が提唱する「概要画面と詳細画面」という可視化デザインに沿った可視化システムを構築する。要件1を満たすために提案手法では、音響特徴量と鑑賞者の嗜好の関係を近似曲線で示すという概要画面により、両者の大局的な傾向を表現する。要件2を満たすために提案手法では、鑑賞者群と楽曲群を連結して構成される2部グラフに対して、Node-link と Matrix の2種類の可視

化手法を適用することで詳細画面を構成し、特定の鑑賞者クラスと楽曲クラスの間に見られる局所的な特徴を表現する。

本論文の主な学術的貢献は以下の通りである。1) 各々の日常行動時に好まれる楽曲とその音響特徴量に着目した可視化、という点で前例の見当たらない研究課題を示している。2) 本研究の目的を満たすために、「概要画面と詳細画面」というデザインポリシーに沿って可視化システムを設計した。3) 好まれる楽曲の日常行動ごとの違いに関する知見を可視化結果から導いた。

2. 関連研究

本章では、複合的なデータを効果的に可視化するための可視化システム設計に関連する研究について紹介する。

2.1 概要画面と詳細画面

音楽鑑賞のデータは楽曲自体の情報（音響特徴やメタデータ）と鑑賞者の情報（再生履歴や日常生活など）が絡んだ複合的なデータである。我々自身による先行研究[8]では、このような複合的なデータの分析には単一の可視化システムでは不十分であることを示唆した。そこで着目したのが、概要画面と詳細画面で構成される可視化システムを提案したCockburnら[7]のアプローチである。Cockburnらは、概要画面と詳細画面をわけることが分析過程において効果的であることを示している。一方で、それらを1つの可視化システムに配置するには2つの問題があるとしている。1点目は、可視化の画面空間に限りがあるという問題である。2点目は、大規模なデータにおいて2つの可視化間の連動に時間がかかり過ぎてしまう問題である。人間が同時に処理できる情報量は限られているため、その量を超えた大量の情報を同時に表現しても、分析の役に立たない可能性がある。そこで本研究では、複数の可視化画面を相互操作することを前提とした可視化システムを開発するのではなく、独立に開発した複数の可視化画面を組み合わせる形で分析を実施する。このように、可視化画面を独立させることによって、1つ1つの可視化を正確に知覚して、分析することができると期待している。

本研究では、概要画面によって日常行動と音響特徴量の関係を解明し、詳細画面によって鑑賞者間の選曲傾向の差異を解明することを目指す。

2.2 Node-link と Matrix

鑑賞者と楽曲の視聴関係のような、データ間の関係性を表現する一般的な可視化手法として、Node-link と Matrixがある。図1にNode-link と Matrixの概略図を示す。これら2つの可視化手法は、同じ情報を表現可能な可視化手法である[9]が、以下のような特徴がある。Node-linkは、可視化結果の直感的な理解において有利であるが、ノードやエッジの重なりを解消することが難しいという問題がある。Matrixは、データ要素間の画面上の重なりが生じないため、全てのデータ要素を均等に可視化することが可能であるが、データセットの規模が大きくなると横または縦に広がってしまうため、画面占有面積を抑えることが難しいという問題がある。このように、データセットの大きさや密度によ

って、視認性が大きく左右されるため、優位性については今もなお議論に決着がついていない[10]. そこで本研究では、どちらか一方に限定せずに、両者の利点を活かした分析を実施する。

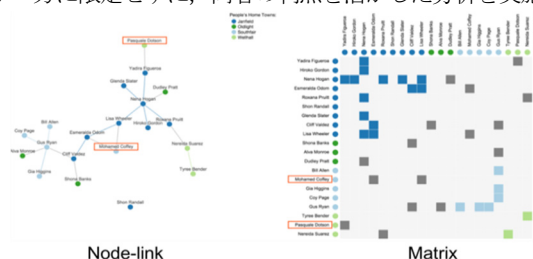


図1 Node-link と Matrix の概略図

本研究では、音楽鑑賞の全体的な特徴や傾向を把握するための近似曲線を概要画面として採用し、より局所的な特徴や傾向を発見するための詳細画面としてネットワーク可視化 (Node-link) とヒートマップ (Matrix) を採用する。以上の3つの可視化システムを組み合わせることで、日常行動と音響特徴量の関係性と鑑賞者間の選曲傾向の差異を分析する。

3. 提案する可視化システム

本章では、3つの可視化手法で構成されるシステムを開発するための各処理について論じる。可視化システムの概要を図2に示す。3.1節では本研究で用いるデータ、3.2節では日常行動と楽曲に関するアンケート、3.3節では1つ目の可視化手法である近似曲線、3.4節では2つ目の可視化手法である Koala というネットワーク可視化手法、3.5節では3つ目の可視化手法であるヒートマップについて説明する。

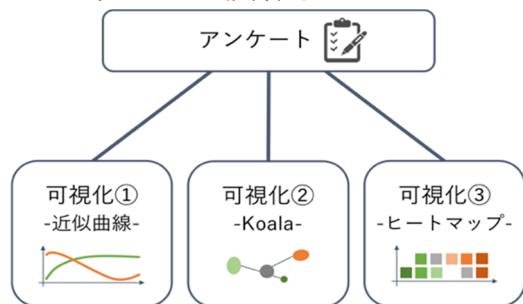


図2 可視化システムの概要

3.1 使用データ

本研究では、日常行動データと音響特徴量データを用いている。以下、各データの詳細について述べる。

3.1.1 日常行動データ

我々は自身の先行研究[7]から、楽曲の視聴場所と音響特徴量には相関があるという知見を得た。これに続く工程として本研究では、活動の場所を一箇所に限定し、日常行動の違いのみに着目して選曲の傾向を分析することとした。

NHKの調査[11]によると、日本人の在宅時間は、1995年から増加傾向にあった。さらに、昨今の新型コロナウイルス (COVID-19) が、在宅時間の増加に拍車をかけている。このように、1日の大半を家で過ごす機会が多くなった現状を鑑みて、

本調査では活動の場所を家に限定した。

我々が採用している日常行動と想定しているシチュエーションを表1に示す。これらの日常行動の選定に際して我々は、先行研究[12], [13]を参考にして、家で想定される全ての日常行動を採用した。

表1 日常行動一覧

日常行動	シチュエーション
食事	1人でご飯を食べている
入浴	湯船に浸かっている
掃除	荷物を片付けている
料理	ご飯を作っている
音楽鑑賞	ゆったりとしている
勉強	レポートを書いている
運動	筋トレをしている

3.1.2 音響特徴量データ

本研究では、音響特徴量解析ツール Librosa[14]を用いて各楽曲の音響特徴量値を算出している。現段階で我々が採用している音響特徴量は、「テンポ、音量、明るさ」の3値である。この3値の定義を表2に示す。ただし、テンポ、音量、明るさはそれぞれスカラー値である。パラメータとして、 $sr = 22050$, $n_fft = frame_length = 2048$, $hop_length = 512$, 窓関数はハン窓を適用している。

表2 音響特徴量一覧

音響特徴量	概要
テンポ (beat_track)	1分間の拍数を示す値。
音量 (rms)	音の大きさを示す値。ある時間ウィンドウ幅における音量振幅の二乗平均平方根。
明るさ (spectral_centroid)	音の明るさを示す値。周波数成分をパワーによって重みつけた平均 (スペクトル平均)。

これらの音響特徴量の選出には、Librosaによって得られる音響特徴量間の相関係数値を適用している。2つの音響特徴量間の相関係数が0に近いということはつまり、数学的にはそれぞれの変数が独立であることを示している。2つの音響特徴量がそれぞれ異なる指標を表している組み合わせを模索した結果として、我々は上記の3値を選出した。ただし、テンポ (beat_track) の値は、4ビートや8ビート等の識別が難しく、算出結果に誤りが生じてしまったため、明らかに誤りとわかる算出結果については手で修正した。また、音量 (rms) と明るさ (spectral_centroid) は、単位時間ごとに特徴量値を算出しているため、1曲に対して一意に定まっていない。そのため、本手法では算出された値の平均値を各楽曲の音響特徴量とした。

3.2 アンケート

アンケートでは、各日常行動に対する選曲を調査した。アンケートに使用したフォームの概要を図3に示す。本アンケートでは、2012~2013年にCDの売り上げが高かった50曲と、3.1.1項で述べた7つの日常行動のマトリクス形式で実施した。マトリクス形式にすることによって、「聴きたい曲、聴きたくない曲、どちらでもない曲」の3段階で、日常行動と楽曲の全ての組み合わせに対して評価をしてもらった。本アンケートで用いる楽曲には、

多くの被験者にとって耳馴染みのある時期の楽曲とするために、2012～2013年の楽曲を選定した。回答者がタイトルをみただけで楽曲を思い出せるとは限らないので、回答者には各楽曲ともに全体を視聴してもらうことで、各楽曲への記憶や理解がばらつかないようにさせた。また、想定する視聴環境の違いによって、アンケート結果に差が生じてしまう可能性がある。そのため、スピーカを用いて一人で聴いていることを想定してもらうことで視聴環境を統一した。

	行動1	行動2	行動3	...
楽曲1				
楽曲2				
楽曲3			○	
⋮			○ - x	

○: 聴きたい
-: どちらでもない
x: 聴きたくない

図3 アンケートフォーム

3.3 可視化① -近似曲線-

鑑賞者の選曲と音響特徴量との全体的な傾向を把握するために、本研究では近似曲線を可視化手法として採用する。音響特徴量をテンポとした可視化画面を図4に示す。

この可視化では、楽曲を横軸に沿って左右に並べている。音響特徴量の値によって楽曲を左から右へ順にソートすることで、視認性の向上を図っている。図4の例では、テンポが遅い楽曲が左側、テンポが速い楽曲が右側に配置されている。また、横軸のプロット幅は楽曲の音響特徴量を正規化することで調節している。縦軸は、それぞれの行動において、各楽曲に対してアンケートで「聴きたい」を選択した鑑賞者の割合を表している。各曲に対する縦軸の割合 x は以下の式(1)によって算出される。

$$x = \frac{n}{N} \quad (1)$$

n: 「聴きたい」を選択した鑑賞者数
N: 評価した鑑賞者数

また、可視化画面図4の下に設置したスライダーを操作することによって、曲線の次数を1から10まで、10段階で調節することが可能である。

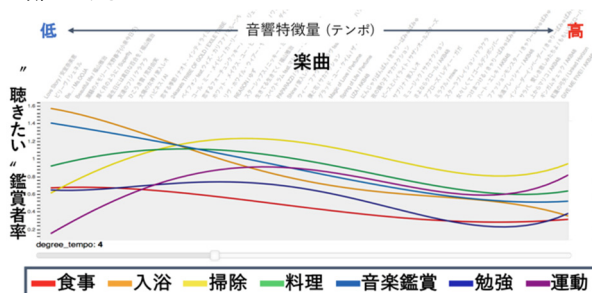


図4 近似曲線による可視化画面

3.4 可視化② -Koala-

各鑑賞者の楽曲視聴に関する局所的な傾向を把握するために、本研究はネットワーク可視化手法である Koala[17]を拡張する形で採用する。Koalaとは、ノードをクラスタリングして配置するグラフ可視化手法である。日常行動を入浴とした可視化画面を図5に示す。

この可視化では、鑑賞者と楽曲の両方がノードとして描画されている。エッジは、3.2節で調査したアンケート項目（聴きたい曲、聴きたくない曲、どちらでもない曲）のうち、可視化したい関係にもとづいて生成している。例えば、鑑賞者が「聴きたい」とした楽曲との視聴関係を可視化したい場合は、鑑賞者が各日常行動中に「聴きたい」とした楽曲をエッジで連結している。図5では鑑賞者が入浴中に「聴きたい」とした楽曲をエッジで結んでいる。この処理の結果として、鑑賞者群と楽曲群を連結する2部グラフが構築される。

Koalaはクラスタを単位として各ノードを画面に配置する。それぞれのクラスタは 1) 選曲の共通性の高い鑑賞者のノード、 2) 鑑賞者の共通性の高い楽曲のノードで構成されている。ノードを配置するためのアルゴリズムを以下に記載する。

1. クラスタをノードに置き換えたグラフを生成し、これに対してグラフ配置アルゴリズムを適用。
2. 各クラスタを構成するノード数から、各クラスタの半径を計算。
3. エッジ長が両端のノードの半径の合計値にできるだけ近くようにスムージング処理を適用。
4. クラスタ内にそのクラスタを構成するノードを配置。

以上の手順によって、同じクラスタに分類されたノードを近くに配置する。

ノードは鑑賞者の属性および楽曲の音響特徴量で配色されている。図5では、鑑賞者に対応するノードは性別で配色されており、楽曲に対応するノードは音量で配色されている。楽曲ノードと鑑賞者ノードを視覚的に判別するために、本研究では異なる色相を両者に割り当てている。楽曲ノードでは、各音響特徴量の値を表している。音響特徴量の値が小さい値から大きい値へと順に、青から赤のレインボーカラーを割り当てている。鑑賞者ノードの色は各鑑賞者の属性を表している。現時点の実装では、鑑賞者の性別と3年以上の楽器経験の有無の2種類の属性のいずれかを配色に用いている。鑑賞者の性別で鑑賞者ノードを配色する際には、女性にはピンク、男性には紫を割り当てている。鑑賞者の楽器経験で鑑賞者ノードを配色する際には、楽器経験がある鑑賞者にはピンク、楽器経験のない鑑賞者には紫を割り当てている。

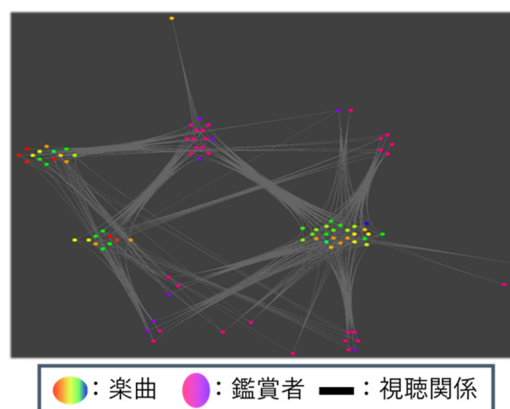


図5 Koalaによる可視化画面

3.5 可視化③ -ヒートマップ-

各鑑賞者の選曲傾向を詳細に把握するために、本研究ではヒ

ートマップを採用する。これによって、鑑賞者間の選曲傾向に違いがあるのかを1曲単位で観察できる。日常行動を音楽鑑賞、音響特徴量をテンポとした可視化画面を図6に示す。

楽曲は横軸に沿って並べられている。3.3 節の近似曲線と同様に、音響特徴量の値によるソートを適用している。鑑賞者は縦軸に沿って並べられている。鑑賞者に階層クラスタリングを適用することによって、選曲傾向が類似している鑑賞者が近くに配置されるように並び順を決定し、選曲傾向の視認性を向上させる。

階層クラスタリングでは、要素間の類似度（距離）にもとづいて、最も類似度の高い要素から順に凝集することでクラスタを作る。本手法では、鑑賞者ごとの「聴きたい」を選択した楽曲群にもとづいて、以下の手順によってクラスタリングを実施した。

1. 音響特徴量の値が低い楽曲から順に5曲ずつ分割。
2. 5曲ごとに、鑑賞者ごとに「聴きたい」を選択した楽曲の音響特徴量平均値のリストを算出。
3. リスト間のユークリッド距離を算出。

以上の手順により、選曲傾向が類似している鑑賞者を近くに配置した。なお本研究では、距離算出にはユークリッド距離を適用し、クラスタ間の距離算出には完全連結法を採用した。これは、各々のクラスタの中で最も距離の大きいベクトル間距離をそのクラスタ間の距離とするものである。

また、プロットの色には、3.2節のアンケートで分類した、「聴きたい曲、聴きたくない曲、どちらでもない曲」の3段階の色を割り当てている。鑑賞者が「聴きたい」とした楽曲には、音響特徴量が小さい値から大きい値へ順々に、緑から赤の色を割り当てている。鑑賞者が「聴きたくない」とした楽曲、「どちらでもない」とした楽曲には、それぞれ灰色と白色を割り当てている。




図6 ヒートマップによる可視化画面

4. 実行例

本章では、3つの可視化システムによる分析結果について論じる。4.1節では可視化に使用した実験参加者の詳細について述べる。4.2節では1つ目の可視化手法である近似曲線、4.3節では2つ目の可視化手法であるKoala、4.4節では3つ目の可視化手法であるヒートマップの分析結果について述べる。

4.1 実験参加者の詳細

3.2節で実施したアンケートでは、18歳から30歳（平均年齢22歳）の男女44人の回答を得た。回答者のうち33人が女性、

11人が男性であった。一方で、Geringerら[15][16]の研究によると、3年以上の楽器経験の有無が選曲に影響を与えるとされている。これを検証するために本アンケートにおいても、回答者が楽器を経験したことがあるかを調査した。その結果、今回の回答者のうち、30人が3年以上の楽器経験があり、14人が楽器を経験していなかった。

4.2 近似曲線

3.3節の手順で算出した曲線上のいくつかの点を用いて、各行動間の選曲傾向の類似性を分析した。行動間の類似度算出にはコサイン類似度を用いた。

コサイン類似度とは、ベクトル空間モデルにおいて、ベクトルの内積を用いて類似度を算出する方法である。1に近いほど類似しており、1よりも小さいほど類似していないことを示す。本研究では、3つの音響特徴量ごとに、各日常行動のコサイン類似度 $\cos(\theta)$ を、以下の式(2)によって算出した。ここで、曲線を等間隔に分割した際の、分割点のリストを曲線ベクトル A, B とした。なお本研究では、曲線を4等分に分割して得られた、5つの分割点による「聴きたい鑑賞者の割合」を5次元ベクトルとして扱い、 $A = [a_1, a_2, a_3, a_4, a_5]$ 、 $B = [b_1, b_2, b_3, b_4, b_5]$ とする。

$$\cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_i a_i b_i}{\sqrt{\sum_i a_i^2} \times \sqrt{\sum_i b_i^2}} \quad (2)$$

式(2)によって算出したコサイン類似度を、以下の表2に示す。表2では視認性向上のため、各日常行動において、最も類似度が高かった値を強調表示している。この結果によると、入浴と音楽鑑賞、食事と勉強と料理、掃除と運動はそれぞれ選曲傾向が類似していることが読み取れる。

表2 コサイン類似度算出表

				掃除		運動	
				0.98028	0.93151		
		勉強		0.99409	0.95602	0.89453	
		食事		0.99473	0.99166	0.95063	0.88191
		音楽鑑賞		0.99173	0.98840	0.97480	0.91794
		入浴		0.99786	0.98350	0.97638	0.95951
					0.89454	0.93151	

表2より分類した3種類の選曲傾向と音響特徴量との相関を視認によって確認した。視認性向上のために、可視化画面下のスライダーを用いて、次数を1にした可視化画面を図7に示す。1つ目の選曲傾向は、入浴と音楽鑑賞である。これらは、どちらも傾きが右下がりになっている。すなわち、音量が小さい楽曲が好まれるという点で選曲傾向が類似している。2つ目の選曲傾向は、食事と勉強と料理である。これらは、いずれも傾きがなく、水平である。すなわち、選曲された楽曲は、音響特徴量による差異がないという点で選曲傾向が類似している。3つ目の選曲傾向は、掃除と運動である。これらは、どちらも傾きが右上がりになっている。すなわち、音量が大きい楽曲が好まれるという点で選曲傾向が類似している。




図7 次数1の近似曲線可視化画面

以上の分析を3つの音響特徴量の各々において施した結果を表3に示す。表3より、3.1.1節に示した7項目の日常行動は、大きく3種類の選曲傾向に分類される。入浴と音楽鑑賞には、スローテンポ・小音量・暗い、バラードのような曲調の楽曲が好まれる傾向にある。食事と勉強と料理には、音響特徴量による差異がほとんど見られない。掃除と運動は、アップテンポ・大音量・明るい、バンドやアイドルソングのような曲調の楽曲が好まれる傾向にある。

表3 選曲傾向の分類

	入浴	音楽鑑賞	食事	勉強	料理	掃除	運動
テンポ	遅	遅	差異なし	差異なし	差異なし	速	速
音量	小	小	差異なし	差異なし	差異なし	大	大
明るさ	暗	暗	暗	差異なし	差異なし	明	明

4.3 Koala

3.4節の手順によって形成された鑑賞者と楽曲のネットワークをKoalaにより観察し、鑑賞者と楽曲の関係を分析した。

4.3.1 アーティスト分類

3.2節で調査したアンケート項目のうち、鑑賞者が「聴きたい」とした楽曲をエッジで連結した場合に、楽曲クラスタの中に同一アーティストが多く分類された。本研究で使用した50曲、合計31組のアーティストのうち、19組のグループが以下の表4に示す4つのグループに分類された。4つのグループのうち、グループ4に含まれるアーティストのほとんどは、洋楽を歌っていた。このことから、洋楽をよく聴く鑑賞者が複数いたことが推測される。また、それぞれの日常行動間でのアーティスト分類には、あまり差異が見られず、全体を通して同じようなグループに分類された。

表4 アーティスト分類

グループ1 <13曲>	グループ3 <6曲>	グループ4 <12曲>
AKB48	サザンオールスターズ	サカナクション
きゃりーぱみゅぱみゅ	ナオトインティライミ	AI
ももいろクローバーZ	superfly	Maroon5
	ケラケラ	Carly Rae Jepsen
	Ms.OOJA	One Direction
グループ2 <3曲>		Lady Gaga
perfume		Rihanna
miwa		Nicki Minaj
		Zeed

グループに分類された。以上の結果から、鑑賞者は日常行動を考慮した選曲とは別に、各鑑賞者が好きな固有のアーティストの楽曲を積極的に選曲していることが推測される。

4.3.2 視聴関係と音響特徴量

3.2節で調査したアンケート項目のうち、鑑賞者が「聴きたくない」とした楽曲をエッジで結んだ場合に、顕著な特徴が見られた。日常行動を入浴と音楽鑑賞、音響特徴量をテンポとした可視化画面を図8に示す。図8に示す青丸の部分には、寒色系のプロットが集まっている。これらのプロットは、楽曲クラスタを表すノードであり、配色が寒色系であるということは、テンポが低いことを表している。つまり、入浴と音楽鑑賞の可視化画面では、テンポが遅い楽曲がクラスタを形成していることを表している。さらに、このクラスタとエッジで結ばれている鑑賞者数は、他のクラスタと比較して少ないことが読み取れる。この可視化画面では、鑑賞者が「聴きたくない」とした楽曲をエッジで結んでいる。そのため、テンポが遅い楽曲を「聴きたくない」としている鑑賞者数は、他のクラスタと比較して少ないということが読み取れる。すなわち、テンポが遅い楽曲を「聴きたい」としている鑑賞者数が多いことを表している。ここで、音響特徴量に明るさを選んだ場合でも、同様の可視化結果が得られた。日常行動を入浴と音楽鑑賞、音響特徴量を明るさとした可視化画面を図9に示す。以上を踏まえると、日常行動が入浴と音楽鑑賞の場合には、鑑賞者は特にテンポと明るさを選曲時に考慮していて、スローテンポで暗い曲調の楽曲が好まれることが読み取れる。

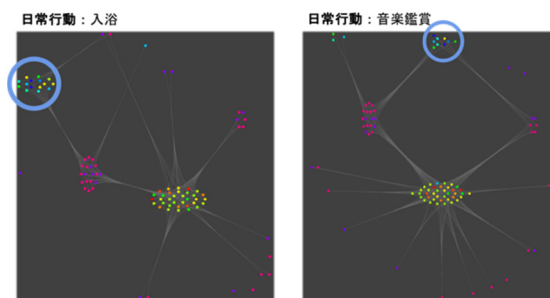


図8 入浴・音楽鑑賞のKoala可視化画面(テンポ)

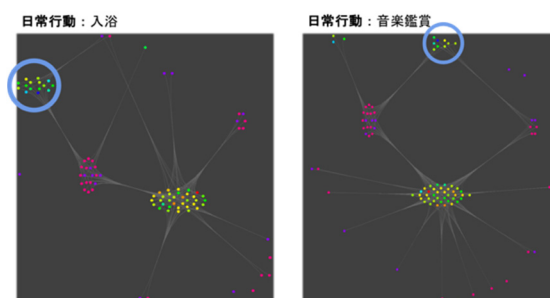


図9 入浴・音楽鑑賞のKoala可視化画面(明るさ)

一方、日常行動を掃除と運動、音響特徴量を音量とした可視化画面を図10に示す。図10に示す赤丸の部分には、暖色系のプロットが集まっている。つまり、掃除と運動の可視化画面では、音量が大きい楽曲のクラスタが形成されていることを表している。また図10でも、このクラスタとエッジで結ばれている鑑賞者数は、他のクラスタと比較して少ない。そのため、音量が大きい楽曲を「聴きたい」としている鑑賞者数が多いことが読み取れる。以上のことから、日常行動が掃除と運動の場合には、鑑賞者は特に音量を考慮した選曲をしていて、音量が大きい楽曲が好まれることが読み取れる。

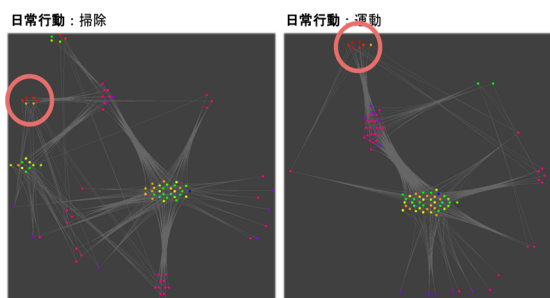


図10 掃除・運動のKoala可視化画面(音量)

図8・図9(入浴と音楽鑑賞)と図10(掃除と運動)の分類は、4.1節で分類された選曲傾向と一致している。ここからも、表3の分類は適切であることが示唆される。また、Koalaによる分析結果から、7項目の日常行動によって重視されている音響特徴量に違いがあることがわかった。

4.4 ヒートマップ

3.5節の手順で形成された階層クラスタリングとヒートマップをもとに、鑑賞者の選曲について分析した。

日常行動を音楽鑑賞、音響特徴量を音量とし、階層クラスタリングを適用した可視化画面を図11に示す。図11の可視化画面右側に表示された階層クラスタリング結果に着目すると、鑑賞者が大きく2つのクラスタに分類されていることを読み取れる。ヒートマップからも鑑賞者の選曲傾向が二分されていることがわかる。下側のクラスタは、ヒートマップ部分において、可視化画面の左から右まで均一に「聴きたい」楽曲が選択されている。このことから、これらのクラスタに含まれる鑑賞者の選曲は音量に相関していないことがわかる。一方上側のクラスタは、ヒートマップの部分において、可視化画面右側の音量が大きい楽曲は、鑑賞者が「聴きたい」とした楽曲が選択されていない。このことから、これらのクラスタに含まれる鑑賞者の選曲は音量に相関していることがわかる。このような、音響特徴量全般に相関した選曲傾向を有する鑑賞者のクラスタは、3.1.1項で示した7項目の日常行動のうち、入浴・音楽鑑賞・食事・勉強・料理の5つの日常行動において見られた。これら5つの日常行動は、4.1節で分類された選曲傾向と一致している。




図11 ヒートマップ可視化画面

続いて、音響特徴量全般に選曲が相関する鑑賞者が多いクラスタを対象として、鑑賞者の特徴を調査した。その結果、楽器経験の有無と大きな関係があることがわかった。図12では、音響特徴量に選曲が相関する鑑賞者が多いクラスタにおける、楽器を経験していた鑑賞者の割合をグラフとして図示した。ただし、日常行動が料理、音響特徴量が音量の場合は、選曲傾向の違いを確認できなかったため、グラフを省略している。本アンケートに回答してくれた鑑賞者のうち、楽器経験者の割合は

70%未満である。それに対して、図12に示す結果から、クラスタに含まれる楽器経験者の割合が全体的に高いことが読み取れる。特に、楽曲の明るさとテンポはどの日常行動を見ても楽器経験者の割合が非常に高い。以上により、楽器経験者の選曲には、テンポや明るさとの相関が高いことがわかった。




図12 当該クラスタにおける楽器経験鑑賞者の割合

4.5 考察と議論

3つの可視化システムによる分析結果のまとめを図13に示す。今回のアンケート結果を可視化することで、鑑賞者はそれぞれの日常行動に適するような音響特徴量の楽曲を選曲していること、加えて選曲に相関する音響特徴量は日常行動によって異なることがわかった。また、鑑賞者ごとに選曲傾向が異なる日常行動と、鑑賞者全体にわたって同様な選曲傾向となる日常行動に分類されることもわかった。

続いて各々の日常行動に着目すると、掃除と運動における楽曲推薦においては、鑑賞者の好きなアーティストを選曲するよりも、音響特徴量、特に音量が選曲に重要であることが示唆される。それに対して、その他の5つの日常行動における楽曲推薦の優先度は、鑑賞者によって個人差があることが見受けられる。これらの日常行動においては、音響特徴量(特に明るさとテンポ)を優先して選曲する鑑賞者、鑑賞者が好きなアーティストの楽曲を優先して選曲する鑑賞者、これらの両方の傾向が現れる鑑賞者、といった3種類の選曲傾向に分類されることが示唆される。

	入浴	音楽鑑賞	食事	勉強	料理	掃除	運動
テンポ	遅	遅	差異なし	差異なし	差異なし	速	速
音量	小	小	差異なし	差異なし	差異なし	大	大
明るさ	暗	暗	暗	差異なし	差異なし	明	明



図13 分析結果のまとめ

このような結果を利用することで、楽曲推薦の説明性を高められると考えられる。言い換えれば、各鑑賞者がどのような選曲傾向を有するかを見極めて、楽曲推薦の優先度を定めることが重要となると考えられる。楽曲推薦の際に、先述したような鑑賞者個人に適合した推薦理由にもとづいていることを提示することで、推薦システムへの信頼度を向上させることができると考える。

以上の結果は、3つの可視化システムを組み合わせることで

総合的に得られた知見である。本研究では、各々の可視化システムに対して「大局的傾向」「局所の特徴」というように解明したい点を明確に役割分担させている。これによって、各々の可視化結果において注目すべき箇所を的確に、瞬時に知覚することが可能となり、それぞれの可視化システムから異なる知見をもたらすことができた。また、独立した複数の可視化結果を照合することによって、それぞれの可視化システムからもたらされた異なる知見の信頼性を互いに担保することを可能としている。この点において、本手法は他の可視化手法と比較して優れていると考えている。さらに本手法では、2.1節で述べた画面効率、処理速度の問題についても解消することができている。これらの理由から、本研究が対象とする複合的なデータにおいては、相互操作が可能な単一の可視化システムではなく、本研究で提案したような独立した複数の可視化システムを組み合わせる手法がより分析に適していると考えられる。

5. まとめと今後の課題

本論文では、楽曲推薦における重要な知見と考えられる日常行動と音響特徴量の関係を可視化するシステムを提案した。本システムでは大局的傾向を表現するために近似曲線を適用し、局所の特徴を表現するために Node-link および Matrix の 2 種類の可視化手法を適用した。そして我々自身で実施したアンケートに沿って鑑賞者群と楽曲群の関係を可視化した結果から、日常行動と音響特徴量の関係が楽曲推薦における重要な知見である可能性を示した。

今後の課題として、鑑賞者属性を考慮した分析の充実、可視化システム間の連携強化の 2 点を目標としている。1 点目の鑑賞者属性とは、現時点では鑑賞者の性別と楽器経験の有無といった情報を指す。これらの属性を考慮した分析については、現時点では 3 つ目の可視化システムであるヒートマップでしか傾向を発見できていない。そのため、他の可視化システムでも分析を進め、さらに新しい分析結果の解明に努めたい。2 点目の可視化システム間の連携強化については、本報告における分析結果からも、3 つの可視化システムを組み合わせることによって、解明された点が多いことがわかる。そこで、3 つの可視化システム間の連携をより強化することによって、さらなる分析を実施したいと考えている。連携を強化するための一例として、鑑賞者が好きなアーティストの楽曲を除外したデータで再度可視化することを想定している。

参考文献

- [1] Barry Schwartz, "The Paradox of Choice: Why More Is Less", Harper Perennial, 2005.
- [2] Yading Song, Simon Dixon, "Marcus Pearce : A Survey of Music Recommendation Systems and Future Perspectives", M Pearce 9th International Symposium on Computer Music Modeling and Retrieval 4, pp. 395-410, 2012.
- [3] Zhiyong Cheng, Jialie Shen, "On Effective Location-Aware Music Recommendation", Submitted to ACM TOIS, pp. 13:1-13:32, 2016.
- [4] Xinxi Wang, David Rosenblum, Ye Wang, "Context-Aware Mobile Music Recommendation for Daily Activities", In Proceedings of the ACM International Conference on Multimedia, pp. 99-108, 2012.
- [5] Pirkka Åman, Lassi A Liikkanen, "Interacting with Context Factors in Music Recommendation and Discovery", International Journal of Human-Computer Interaction, 33(3), pp.165-179, 2017.
- [6] Nava Tintarev, Judith Masthoff, "A survey of explanations in recommender systems", IEEE 23rd International Conference on Data Engineering Workshop, pp. 801-810, 2007.
- [7] Andy Cockburn, Amy Karlson, Benjamin B. Bederson, "A review of overview+detail, zooming, and focus+context interfaces", ACM Computing Surveys, vol. 41, pp. 2:1-2:31, 2009.
- [8] Narumi Kuroko, Hayayo Ohya, Takayuki Itoh, Nicolas Grossmann, Hsiang-Yun Wu, "Visualization of Correlations between Places of Music Listening and Acoustic Features", In Proceedings of the 24th International Conference on Information Visualisation (iV2020), pp. 22-27, 2020.
- [9] Donghao Ren, Laura R. Marusich, John O'Donovan, Jonathan Z. Bakdash, James A. Schaffer, Daniel N. Cassenti, Sue E. Kase, Heather E. Roy, Wan-yi (Sabrina) Lin, Tobias Höllerer, "Understanding Node-Link and Matrix Visualizations of Networks: A Large-scale Online Experiment", Network Science, 7(2), pp. 242-264, 2019.
- [10] Mershack Okoe, Radu Jianu, Stephen Kobourov, "Revisited network representations," in 25th Symposium on Graph Drawing (GD), 2017.
- [11] NHK 放送文化研究所, "2015 年国民生活時間調査報告書", 2015.
- [12] Sergey Volokhin, Eugene Agichtein, "Understanding Music Listening Intents During Daily Activities with Implications for Contextual Music Recommendation", In Proceedings of the 2018 Conference on Human Information Interaction & Retrieval (CHIIR '18), pp. 313-316, 2018.
- [13] Adrian C. North, David J. Hargreaves, Jon J. Hargreaves, "Uses of music in everyday life. Music Perception", 22(1), pp. 41-77, 2004.
- [14] Brian McFee, Colin Raffel, Dawen Liang, Daniel P.W. Ellis, Matt McVicar, Eric Battenberg, Oriol Nieto, "librosa: Audio and Music Signal Analysis in Python", Proc. of the 14th Python in Science Conf. (SCIPY), pp. 18-24, 2015.
- [15] Clifford K. Madsen, John M. Geringer, "Differential patterns of music listening: Focus of attention of musicians versus Nonmusicians", Bulletin of the council for Research in Music Education, 105, pp. 45-47, 1990.
- [16] John M. Geringer, Clifford K. Madsen, "Focus of attention to element: Listening patterns of musicians and Nonmusicians", Bulletin of the Council for Research in Music Education, 127, pp. 80-87, 1995.
- [17] Takayuki Itoh, Karsten Klein, "Key-node-Separated Graph Clustering and Layout for Human Relationship Graph Visualization", IEEE Computer Graphics and Applications, Vol. 35, No. 6, pp. 30-40, 2015.

表5 アンケート使用曲一覧

タイトル	アーティスト
ハビネス	AI
恋するフォーチュンクッキー	AKB48
さよならクロール	AKB48
永遠プレッシャー	AKB48
ハート・エレキ	AKB48
GIVE ME FIVE!	AKB48
ギンガムチェック	AKB48
UZA	AKB48
上からマリコ	AKB48
24karats TRIBE OF GOLD	EXILE TRIBE
紅蓮の弓矢	Linked Horizon
ミラクル	miwa
Be...	Ms.OOJA
Magic of Love	Perfume
Spring of Life	Perfume
輝く月のように	Superfly
コール・ミー・メイビー	カーリー・レイ・ジェプセン
にんじやりばんばん	きゃりーぱみゅぱみゅ
インベーターインベーター	きゃりーぱみゅぱみゅ
つけまつける	きゃりーぱみゅぱみゅ
ファッションモンスター	きゃりーぱみゅぱみゅ
スターレイション	ケラケラ
友達のフリ	ケラケラ
女々しくて	ゴールデンボンバー
グラッド・ユー・ケイム	ザ・ウォンテッド
ミュージック	サカナクション
僕と花	サカナクション
夜の踊り子	サカナクション
ピースとハイライト	サザンオールスターズ
ビリーヴ	シェネル
スペクトラム feat.マシュー・コーマ	ゼッド
恋する季節	ナオト・インティライミ
スターシブス	ニッキー・ミナージュ
ペイフォン feat.ウィズ・カリファ	マルーン5
サラバ、愛しき悲しみたちよ	ももいろクローバーZ
REASON	ゆず
ウィー・ファウンド・ラヴ feat.カルヴィン・ハリス	リアーナ
アブローズ	レディー・ガガ
リヴ・ホワイル・ウィアー・ヤング	ワン・ダイレクション
ホワット・メイクス・ユー・ビューティフル	ワン・ダイレクション
Love Story	安室奈美恵
太陽の女神	家入レオ
Shine	家入レオ
サブリーナ	家入レオ
ひこうき雲	荒井由実
PAPARAZZI	少女時代
潮騒のメモリー	天野春子(小泉今日子)
誕生日には真白な百合を	福山雅治
生きてる生きてく	福山雅治
Beautiful life	福山雅治

黒子 なるみ



2019年お茶の水女子大学情報科学科卒業。2021年お茶の水女子大学大学院人間文化創成科学研究科理学専攻 博士前期課程修了。

大矢 隼士



2010年早稲田大学理工学部応用物理学学科卒業。2012年早稲田大学大学院先進理工学研究科物理学及応用物理学専攻修士課程修了。2017年株式会社レコチョク入社。2018年早稲田大学大学院先進理工学研究科物理学及応用物理学専攻博士後期課程満期退学。2021年Septeni Japan株式会社入社、現在に至る。データサイエンティストとしてマルチメディアデータ解析に従事。

伊藤 貴之



1990年早稲田大学理工学部電子通信学科卒業。1992年早稲田大学大学院理工学研究科電気工学専攻修士課程修了。同年日本アイ・ビー・エム(株)入社。1997年博士(工学)。2003年から2005年まで京都大学大学院情報学研究科COE研究員(客員助教授相当)兼任。2005年お茶の水女子大学理学部情報科学科助教授。2011年同大学教授。2019年から同大学文理融合AI・データサイエンスセンター長兼任。情報可視化、音楽情報処理、コンピュータグラフィックス、インタラクション、データ工学などの研究に従事。