

TREXIV: 時刻スタンプ付き高次元データのための 対話的可視化に基づくトレンド抽出手法

中村 栄太[†] 伊藤 貴之^{††}

[†] 京都大学 〒606-8501 京都府京都市左京区吉田本町

^{††} お茶の水女子大学 〒112-8610 東京都文京区大塚 2-1-1

E-mail: teita.nakamura@i.kyoto-u.ac.jp, titot@is.ocha.ac.jp

あらまし 本稿では、時刻スタンプ付き高次元データのためのトレンド抽出手法について述べる。この種のデータ分析は、音楽や絵画を含む創作文化の進化研究で重要である。高次元の空間の中で進化分析に有意義なトレンドを抽出するためには、複数の創作ジャンルが混ざったデータから注目するデータ領域および時間区間を選択し、解釈可能な特徴量の方向を見出す必要がある。これには、高次元空間の中で時間方向と高い相関を持つ成分を自動で解析する方法に合わせて、対象とする文化領域の知識を持つ専門家がデータを確認しながらトレンドの仮説の立案と検証を行える仕組みが有効だと考えられる。本研究では、対話的可視化手法に基づきユーザがデータの観察を行いながら、データ選択と特徴量方向の次元重みの設定を行うことで有意義なトレンド抽出を行う手法を提案する。ポピュラー音楽のスタイル進化解析への応用例では、多面的なデータ可視化と対話的操作の有効性が確認され、実際に複数の非自明なトレンドを抽出することができた。

キーワード 情報可視化, トレンド抽出, 文化進化解析, ビジュアルアナリティクス, 音楽スタイル進化

Data visualization, trend extraction, cultural evolutionary analysis, visual analytics, music style evolution

1 はじめに

近年、文化発展に関する定量的理解を得る目的で、音楽 [1, 2] や絵画 [3, 4]、文学 [5] などの大規模データから創作スタイルの進化（時間変化）を調べる研究が盛んになっている。こうした研究では、創作物が高次元特徴量で表わされ、制作年などの時刻スタンプ付き高次元データの分析を行うことが多い。同種のデータは生物の形態進化の研究でも扱われ、共通する分析の問題も多い [6]。

データに基づく進化解析では、方向性を持った変化（トレンド）の抽出が重要な課題である [7]。トレンドの存在は、背後に働く力の存在を示しており、進化過程の理解や予測につながるからである [8]。しかし、高次元の空間の中で進化分析に有意義なトレンドを抽出することは容易ではない。まず、創作物データでは、ジャンルなどを表すクラスターごとに異なるトレンドが存在することや特定の時間区間のみ顕著なトレンドが存在することが多いため、適切なデータ領域と時間区間の選択が必要である [9]。クラスタリング手法 [10, 11] を用いてデータを自動で分割することも考えられるが、自動分析のみではクラスターの解釈が必ずしも容易ではなく、創作文化に関する専門知識を持つ人によるデータ選択が必要なことも多い。また、高次元の特徴量には互いに強く相関する次元の組も多く存在する中で、有意義なトレンドに対応する解釈可能な特徴量の方向を見つけることも課題である。

これらの問題を解決するには、高次元空間の中で時間方向と高い相関を持つ成分を自動で解析する方法に合わせて、対象と

する文化領域の知識を持つ専門家がデータを確認しながらトレンドの仮説の立案と検証を行える仕組みが有効だと考えられる。本研究では、対話的可視化手法に基づき、ユーザがデータの観察を行いながら、データ選択と特徴量方向の次元重みの設定を行うことで有意義なトレンド抽出を行う手法を提案する。本研究で提案する可視化システム TREXIV (trend extractor based on interactive visualization) の特徴は、以下の機能を有することである。

- 2次元表現空間での時刻情報付きデータ表示、および、データ領域と時間区間の選択のためのインターフェース
- 非線形可視化空間にて任意の曲線に沿ってデータ点を選択することでその特徴量方向を確認するインタラクション
- 時間方向と高く相関する特徴量空間の方向の自動推定
- PCA（主成分分析）と特徴量次元散布図による補助情報の表示
- 相関プロットと2次元表現空間におけるヒートマップを用いた仮説の検証

本稿では、この手法の構成法について説明し、ポピュラー音楽のスタイル進化解析への応用例をもとに、本手法の有効性の検証を行う。

高次元データの可視化手法として、低次元表現空間での表示とデータ選択を対話的に行う手法 [12] や、特徴量次元間の関係性を次元散布図を用いて可視化する方法 [13] などが提案されている。本研究の手法は、時間方向という特別な次元を持つ高次元のデータを扱うために適切なデータ処理を行い、これらの高次元可視化手法を要素として取り入れた多面的な可視化表示を行う。また、時系列データを対象として、顕著なトレンドが見

られる区間を自動検出するトレンド検出に関する研究 [14, 15] や、時系列データの各時刻を多次元データと見なして次元削減する手法の研究 [16] などがある。本研究では、特徴量空間において解釈可能な方向で顕著なトレンドを示すものを見つけるという異なる問題を扱う。

2 可視化手法

2.1 問題設定

本手法の入力データは、時刻スタンプ t_n と高次元特徴量 $\mathbf{x}_n = (x_{ni})_{i=1}^I$ の対により表されるデータ点 n からなるデータセット $(t_n, \mathbf{x}_n)_{n=1}^N$ である (I は特徴量の次元数)。本手法の目標は、特徴量空間におけるトレンド方向 $\boldsymbol{\beta} = (\beta_i)_{i=1}^I$ で以下の性質を満たすものを抽出することである。

P1 ある時間区間において、時刻スタンプ t_n とトレンド特徴量 $y_n = \sum_{i=1}^I \beta_i x_{ni}$ は高い相関を持つ

P2 トレンド方向は解釈可能な特徴量の方向である
以下では、ある特徴量 z_n と時刻スタンプ t_n の間の相関係数 ρ_z のことを CTD (correlation with time direction) と呼ぶ。 z_n と t_n の平均を \bar{z} と \bar{t} とすると、CTD ρ_z は次で定義される。

$$\rho_z = \frac{\sum_{n=1}^N (z_n - \bar{z})(t_n - \bar{t})}{\left[\sum_{n=1}^N (z_n - \bar{z})^2 \right]^{1/2} \left[\sum_{n=1}^N (t_n - \bar{t})^2 \right]^{1/2}} \quad (1)$$

例えば、上記 P1 は「ある時間区間におけるトレンド特徴量 y_n の CTD が高い値を持つ」と言い換えられる。また、各時刻ごとに計算した z_n の平均値からなる時系列 $\bar{z}_t = \sum_n z_n \delta_{t_n, t} / \sum_n \delta_{t_n, t}$ を特徴量 z_n の平均進化曲線と呼ぶ。

本手法では、以下に説明する対話的可視化手法に基づき、ユーザがトレンド方向の仮説を立て、それを検証することにより、上記の条件を満たすトレンド方向を抽出する。この際、ユーザは各データ次元 i に対する重み $\tilde{\beta}_i$ を指定することによりトレンド方向の仮説を立てるものとし、この $\tilde{\boldsymbol{\beta}} = (\tilde{\beta}_i)_{i=1}^I$ を仮説的トレンド方向と呼ぶ。仮説的トレンド方向は、対話的操作の中で変更を繰り返すことが想定され、最終的にユーザが有意義だと思えるものが得られた時に、本手法の目標が達成されたと言える。また、同じデータセットに対して、複数の有意義な仮説的トレンド方向が得られることもある。

2.2 可視化分析の手順

本手法で可視化表示される要素の一覧を以下に示す (図 1 にスナップショットを示す)。対話的操作のインターフェースとなるものには要素名に † が付いている。

V1 概観パネル †: 2次元表現空間にプロットされたデータが表示され、時刻スタンプはマーカ色として表示される。このパネルはデータ選択のためのインターフェースとしても機能する。時間スライダーはトレンド分析に用いるデータの時間区間を選択するために用いる。

V2 特徴量表示パネル: 選択されたデータの平均特徴量ベクトルと、その全体平均特徴量ベクトルからの差異が表示される。

V3 最適トレンド観察パネル: 統計的手法により推定された

最適トレンド特徴量の分布と平均進化曲線が表示される。

V4 PCA パネル: 選択したデータの 2次元 PCA 空間における散布図が表示される。

V5 次元散布図パネル: 特徴量次元の 2次元表現空間における散布図が表示され、平均進化曲線間の相関に基づく特徴量次元の関係が確認できる。各特徴量次元の CTD はマーカ色として表示される。

V6 次元データ表 †: 各特徴量次元のラベルと特性値が表示される。この表は仮説的トレンド方向の重みを入力するインターフェースとしても機能する。

V7 仮説的トレンド方向表示パネル: 選択されたデータの仮説的トレンド特徴量の分布が表示される。

V8 仮説的トレンド観察パネル: 仮説的トレンド特徴量のデータ分布と平均進化曲線が表示される。

ユーザは、以下に示す手順で本可視化手法を使うものとする。

F1 データ選択フェーズでは、ユーザは概観パネルと特徴量表示パネル、最適トレンド観察パネルを用いてデータを観察し、注目するデータ領域と時間区間を対話的に選択する。

F2 仮説立案フェーズでは、ユーザは次元データ表と PCA パネル、次元散布図パネルなどを用いて、特徴量次元の関連と相互関係を観察し、興味がある仮説的トレンド方向を選択する。

F3 仮説検証フェーズでは、ユーザは仮説的トレンド方向表示パネルと仮説的トレンド観察パネルなどを用いて、仮説的トレンド方向における CTD の有意性とデータ分布を分析する。以上のフェーズは複数回繰り返すことができ、これによりユーザは有意義な仮説的トレンド方向の探求や最適化を行う。

2.3 可視化方法

本節では、2.2節で述べた各可視化要素における可視化の方法について述べる。

2.3.1 概観パネル

2次元空間内で高次元データを表示するために、t-SNE 法 [17] に基づく次元圧縮を行う。多次元尺度構成法 (MDS) など、他の次元圧縮手法を用いることも可能である。データ点間の距離尺度については、分析対象のデータに対して適したものを選択して用いる。例えば、一般的なデータについてはユークリッド距離を用いることが考えられる。また、3章のデータ解析例で扱う確率ベクトルデータに対しては Jensen-Shannon ダイバージェンスを用いることができる。時刻スタンプはマーカ色として表示し、赤 (古い時刻) と緑 (中間)、青 (新しい時刻) を内挿して表示色を決定する。

データ選択では、散布図内で閉曲線を手入力することで囲まれた領域内のデータ点を選択する対話的パネルを用いる。分析に用いるデータの時間区間を選択するためのスライダーも表示する。選択されたデータは、要素 V2 と V3, V4, V6, V7 に表示される。

2.3.2 特徴量表示パネル

選択されたデータの平均特徴量ベクトルと、その全データの平均からのずれを計算し表示する。選択されたデータの集合を $(t_{\tilde{n}}, \mathbf{x}_{\tilde{n}})_{\tilde{n}=1}^{\tilde{N}}$ と記す (以下、選択データと呼ぶ)。まず、全デー

TREXIV: Trend extractor based on interactive visualization

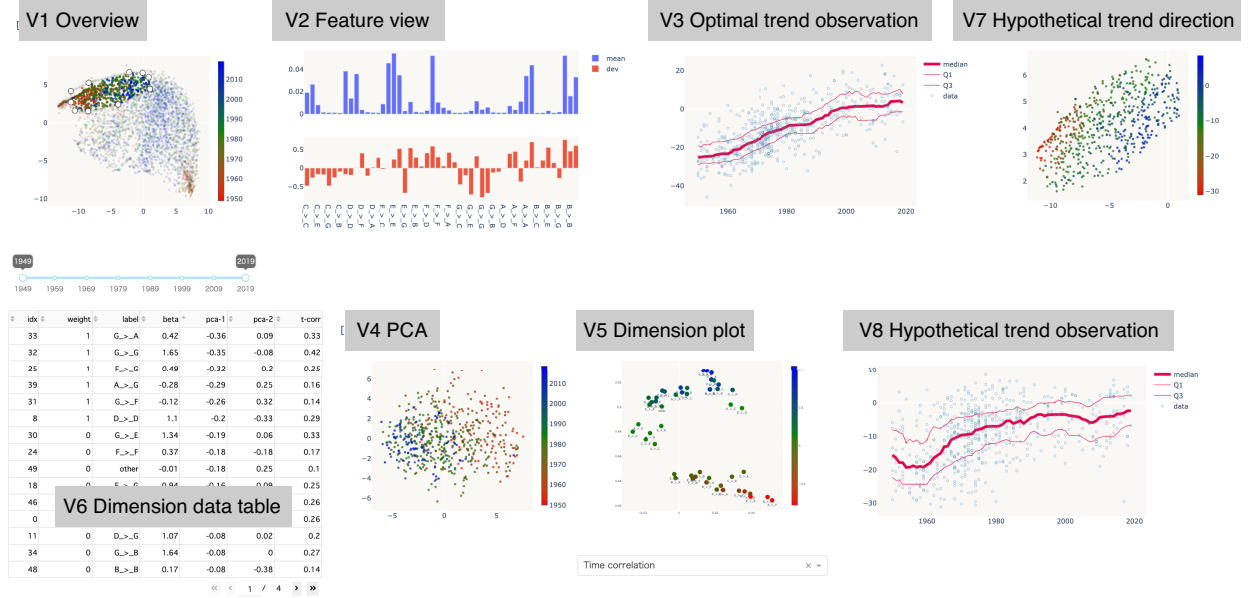


図1 提案する可視化システムのスナップショット。

タの平均 \bar{x}^{whole} と標準偏差 σ^{whole} , および選択データの平均 \bar{x}^{selec} を標準的な方法で計算する。

$$\bar{x}_i^{\text{whole}} = \frac{1}{N} \sum_{n=1}^N x_{ni}, \quad \sigma_i^{\text{whole}} = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_{ni} - \bar{x}_i^{\text{whole}})^2}$$

$$\bar{x}_i^{\text{selec}} = \frac{1}{\tilde{N}} \sum_{\tilde{n}=1}^{\tilde{N}} x_{\tilde{n}i}$$

選択データの全データの平均からのずれ Δ は, $\Delta_i = (\bar{x}_i^{\text{selec}} - \bar{x}_i^{\text{whole}}) / \sigma_i^{\text{whole}}$ で定義する。

2.3.3 最適トレンド観察パネル

選択データに対する最適トレンドを表示するため, 理論的に最大のCTDを持つ特徴量方向 $\beta = (\beta_i)_{i=1}^I$ を計算する。この最適な方向 β は, 計算効率が良い回帰手法によって求める。この方法を導出するため, データが次の生成過程に従うと考える。

$$x_{\tilde{n}i} = \alpha_i t_{\tilde{n}} + \epsilon_{\tilde{n}i} \quad (2)$$

ここで, α_i は定数であり, $\epsilon_{\tilde{n}i}$ は平均ベクトル $\langle \epsilon_{\tilde{n}i} \rangle = \mu_i$ と共分散行列 $\langle \epsilon_{\tilde{n}i} \epsilon_{\tilde{n}'i} \rangle - \mu_i \mu_i' = \Sigma_{ii'}$ を持つガウスノイズである ($\langle X \rangle$ は確率変数 X の期待値を表す)。時刻スタンプ $t_{\tilde{n}}$ は, 基礎統計量を $\langle t_{\tilde{n}} \rangle = \bar{t}$ と $\langle t_{\tilde{n}}^2 \rangle = \bar{t}^2 + s_t^2$ とする確率過程により生成されると仮定する。この時, 第 i 次元の特徴量 $x_{\tilde{n}i}$ のCTD ρ_i は, $\rho_i = \sqrt{\alpha_i^2 / (\alpha_i^2 + \eta_i^2)}$ で与えられる ($\eta_i^2 \equiv \Sigma_{ii} / s_t^2$)。

特徴量 $z_{\tilde{n}}$ を $z_{\tilde{n}} = \sum_i \beta_i x_{\tilde{n}i}$ で定義すると, この特徴量のCTD ρ_z の二乗は次で与えられる。

$$\rho_z^2 = \frac{(\beta \cdot \alpha)^2 s_t^2}{(\beta \cdot \alpha)^2 s_t^2 + \beta^T \Sigma \beta} \quad (3)$$

この表式から, β に対する ρ_z^2 の最大値は次のように求まる。

$$\rho_z^2 = \frac{1}{1 + [(\alpha^T \Sigma^{-1} \alpha) s_t^2]^{-1}} \quad \text{with } \beta \propto \Sigma^{-1} \alpha \quad (4)$$

上で求めた最適な方向 $\beta \propto \Sigma^{-1} \alpha$ を線形回帰手法によって得ることも可能である。この方法では, 近似的な関係 $t_{\tilde{n}} \simeq \sum_i \beta_i x_{\tilde{n}i} + \gamma$ が成り立つように回帰変数の β と γ を求める。漸近極限における平均二乗誤差は次で与えられる。

$$L = \lim_{\tilde{N} \rightarrow \infty} \frac{1}{\tilde{N}} \sum_{\tilde{n}} (z_{\tilde{n}} + \gamma - t_{\tilde{n}})^2$$

$$= (\beta \cdot \alpha - 1)^2 (\bar{t}^2 + s_t^2) + \beta^T \Sigma \beta + \gamma^2 + 2\gamma \bar{t} (\beta \cdot \alpha - 1) \quad (5)$$

この量の最小化の解は $\beta \propto \Sigma^{-1} \alpha$ となる。従って, 式(2)の仮定の下で, 線形回帰とCTDの最大化は等価な結果をもたらす。

生成過程が未知の実データの場合, 最適な方向 β は線形回帰手法によって効率的に推定できる。平均二乗誤差 $L = (1/\tilde{N}) \sum_{\tilde{n}} (\beta \cdot x_{\tilde{n}} + \gamma - t_{\tilde{n}})^2$ の最小化から次の解が得られる。

$$\beta = M^{-1} V, \quad M_{ij} = \frac{1}{\tilde{N}} \sum_{\tilde{n}} (x_{\tilde{n}i} - \bar{x}_i)(x_{\tilde{n}j} - \bar{x}_j) \quad (6)$$

$$V_i = \frac{1}{\tilde{N}} \sum_{\tilde{n}} (x_{\tilde{n}i} - \bar{x}_i)(t_{\tilde{n}} - \bar{t}) \quad (7)$$

ここで, $\bar{x}_i = (1/\tilde{N}) \sum_{\tilde{n}} x_{\tilde{n}i}$ である。上述の等価性によって, データに含まれる非線形性が大きくなければ, この方法で推定された方向は近似的に最適であると期待される。そこで, 本研究の可視化システムではこの方法を実装する。

最適な方向 β が得られた後, 選択データを, 縦軸に対応する特徴量 $z_{\tilde{n}} = \sum_i \beta_i x_{\tilde{n}i}$ で横軸を時刻とする散布図によって表示する。また, 相関係数とp値の計算して, パネル内に表示する。傾きの時間変化を含む場合も含め, トレンドの発見を視覚的に容易にするため, 各時間スライスにおけるデータサンプルから計算した中央値と第一分位点, 第三分位点も表示する。




図2 (a) 音高クラス統計量データに対する概観パネル. 右下領域の選択データに対する (b) 概観パネルと (c) 特徴量表示パネル.

2.3.4 PCA パネル

このパネルには、選択データの特徴量から計算した第一および第二主成分を表示する。概観パネルと同様に、時刻スタンプはマーカ色として表示する。各時間スライス内での分散に比べて時間変化が大きい場合には、トレンドの次元は主成分に含まれるため、PCA は興味あるトレンドを見つけるために役立つことがある。また、第一・第二主成分を見ることにより、2つの独立なトレンドやトレンドに対して各時間スライスで直交する主成分方向を見つけられることもある。

PCA パネルは、概観パネル内で局所的な曲線や直線に対応する特徴量の方向を確認するためにも用いることができ、これはトレンド方向の仮説を立てるための有効な手がかりとなり得る。一般的に、t-SNE 法や多次元尺度構成法などの非線形写像を用いた低次元表現空間において、局所的な曲線に対応する特徴量の方向を理解することは難しい。このような場合、ユーザはこの曲線に沿ってデータ点を選択するば、第一主成分として対応する特徴量方向が確認できることが多い。

2.3.5 次元散布図パネル

このパネルの機能は、ユーザが特徴量の次元間の関係性および、各特徴量次元と時間方向との関係性を理解するのを助けることである。例えば、解釈可能な仮説的トレンド方向を見つけるためには、時間方向と強く相関する特徴量次元のグループで、各次元の平均進化曲線同士も相関しているものを観察して、トレンドの「意味」を理解することが一般的には有用である。また、その様な特徴量次元のグループと平均進化曲線が負の相関を持つ特徴量次元のグループや、時間方向に対して大きな負の相関を持つ特徴量次元のグループを観察することも有益なこともしばしばある。

このような観察を可能とするため、平均進化曲線が互いに強く相関している特徴量次元同士を近づけて、逆に、負の相関を持つ特徴量次元同士を遠ざけるように特徴量次元をプロットする。より正確には、第 i 次元特徴量の平均進化曲線を \bar{x}_{it} と表す時、第 i 次元と第 j 次元の相関 ξ_{ij} は、ペアデータ $(\bar{x}_{it}, \bar{x}_{jt})$ の相関係数として計算する。そして、これらの次元の間の距離を $1 - \xi_{ij}$ と定義して、t-SNE 法などの次元圧縮法を適用することで2次元表示を得る。この散布図において、第 i 次元特徴量のCTD ρ_i をマーカ色で表示し、赤 ($\rho_i = -1$) と緑 ($\rho_i = 0$)、青 ($\rho_i = 1$) を内挿して表示色を決定する。

2.3.6 次元データ表

この表は仮説の立案と仮説の検証のフェーズを結びつける道具としての機能を持つ。各行は特徴量次元を表し、各列には(分析データごとに与えられた)次元ラベル、最適な方向の重み β_i 、および第一・第二主成分の因子負荷量 $PCA1_i$ と $PCA2_i$ が表示される。これらの列の値はトレンドに関係する特徴量次元を見つけ出すのに用いられる。

別の列には、仮説的トレンド方向の重み $\tilde{\beta}_i$ が表示される。ユーザはこれらの重みを編集することで、トレンドの仮説を立案できる。トレンド仮説の検証フェーズでは、これらの重みの値が読み込まれ、仮説的トレンド方向表示パネルと仮説的トレンド観察パネルの表示に用いられる。

2.3.7 仮説的トレンド方向表示パネル

このパネルでは、選択データが概観パネルと同じ座標に散布図として表示される。仮説的トレンド特徴量 $y_{\tilde{n}} = \sum_i \tilde{\beta}_i x_{\tilde{n}i}$ の値がマーカ色として表示され、表示色には概観パネルと同様のグラデーションが用いられる。

2.3.8 仮説的トレンド観察パネル

このパネルでは、最適トレンド観察パネルと同じ方式で、仮説的トレンド特徴量 $y_{\tilde{n}}$ と時刻スタンプ $t_{\tilde{n}}$ が表示される。特徴量 $y_{\tilde{n}}$ のCTD と p 値、そして、中央値と第一分位点、第三分位点の曲線も表示される。

3 音楽スタイル進化解析への応用

本章では提案する可視化システムを用いた解析例として、音楽スタイルの進化解析に応用した結果について述べる。使用するデータは、20世紀後半以降にリリースされた日本のポピュラー音楽の約3000曲のボーカルメロディー部分をMusicXML形式で整備したものである[9]。メロディーは音符の記号列で表され、各音符は相対音高クラス(楽曲を自然調に移調した時の音高からオクターブの情報を除いたもの)と拍節位置(発音時刻を表す小節内の相対位置で、1小節を48分割した単位で表す)のペアで表される。

3.1 解析例1:メジャー系音階の進化

3.1.1 特徴量の抽出

メロディーの音高に関する作曲スタイルを表す特徴量として、音高クラスのバイグラム確率を用いる。このバイグラム確率は、各作品のメロディーデータ内の連続する音高クラスの遷移の同

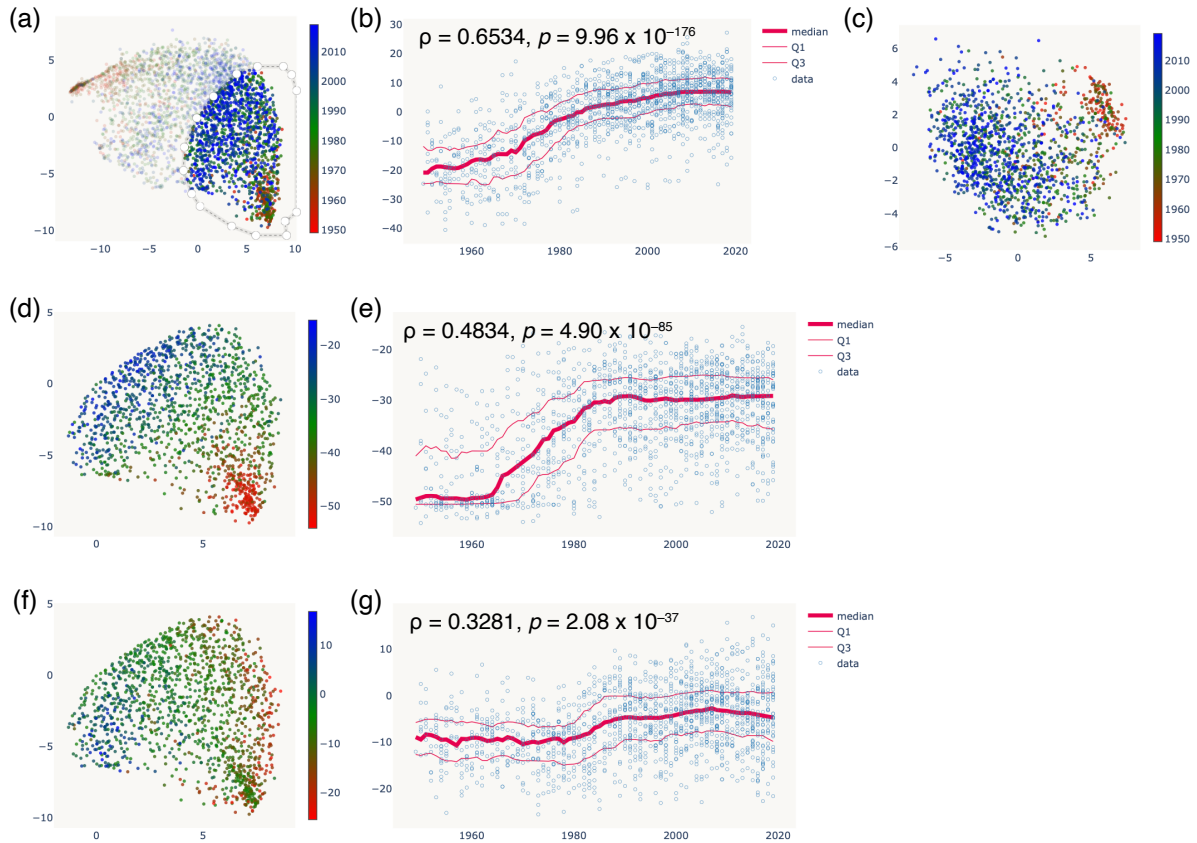


図3 メジャー系音階の進化解析におけるトレンド抽出で用いた可視化画面。

時確率であり、音高クラスは $\{C, C\#, \dots, B\}$ の12種類存在するため、 12^2 次元の統計量である。解析では、音階音に対応する7つの音高クラス $\{C, D, E, F, G, A, B\}$ の間の遷移とそれ以外の other 遷移に分けて考えて、 $7^2 + 1 = 50$ 次元の特微量として扱う。

3.1.2 データ選択フェーズ

このデータでは2つの大きなトレンドの存在が概観パネルで確認できた(図2)。それぞれ、右下領域から中央領域に向かうものと、左上領域から中央領域に向かうものである。右下領域が選択された時の特微量表示パネルを調べると、この領域はメジャー五音階として知られる、FとBの使用を制限した音階を表していることが確認できた。同様に、左上領域は、日本の伝統音楽で陰音階として知られる、マイナー五音階を表していること、そして、中央領域は西洋音楽で標準的に使われる全音階を表していることが確認できた。従って、確認された2つのトレンドはメジャーおよびマイナーの五音階が主流だった時代から全音階が主流になった時代への動きとして解釈できる。以下では、メジャー音階の進化に注目して、右領域のデータを選択した結果について述べる(図3(a))。

3.1.3 仮説立案フェーズ

最適トレンド観察パネルでは、特に1960年から1990年にかけて、最適トレンドの方向に大きな増加が見られた(図3(b))。この場合は、前節における観察から、重要となる特微量を予想することができる。つまり、このトレンドは、FとBを含むバイグラムの確率に関係していると期待される。確認すると、最

適トレンド方向 β の重み係数が大きな特微量方向は、これらの特微量を確かに含んでいたものの、それら以外に、直ぐには解釈可能なトレンドと結び付かない特微量次元も含まれていた。

PCAパネルでは、第一主成分が明確なトレンドを示した(図3(c))。第一主成分の係数が最も小さい次元には、 $F \rightarrow F$, $F \rightleftharpoons E$, $B \rightarrow B$, $B \rightleftharpoons A$ などの五音階から全音階への変遷と直結する特微量が含まれていた。一方で、係数が最も大きな次元には、 $E \rightleftharpoons G$ など、この変遷とは一見、関係がない特微量が含まれていた。実は、これらの音高クラス遷移は、五音階では順次進行(隣り合う音高への進行)であり、頻度が高い一方で、全音階ではもはや順次進行ではないため、頻度が小さくなるものである。これらの考察に基づき、メジャー系音階の進化では次の様なトレンド仮説(HP1)を立案した。

HP1 FとBを含む同音進行と順次進行($F \rightarrow F$ と $F \rightleftharpoons E$, $F \rightleftharpoons G$, $B \rightarrow B$, $B \rightleftharpoons A$, $B \rightleftharpoons C$)に対しては $\tilde{\beta}_i = 1$, FとBをまたぐ遷移($E \rightleftharpoons G$ と $A \rightleftharpoons C$)に対しては $\tilde{\beta}_i = -1$, それ以外の音高クラス遷移に対しては $\tilde{\beta}_i = 0$ 。

PCAパネルでは、第二主成分においても中程度のトレンドが見られた(図3(c))。この因子負荷ベクトルを調べると、係数が最も小さい次元には $A \rightarrow A$, $A \rightleftharpoons B$, $A \rightleftharpoons E$ などのマイナー音階で多く現れる音高クラス遷移が見つかり、最も大きな次元には $C \rightarrow C$, $C \rightleftharpoons D$, $C \rightleftharpoons E$ などのメジャー音階で多く現れる音高クラス遷移が見つかった。この観察によって、マイナーからメジャーへの変遷に関する、もう一つトレンド仮説(HP2)を立案することができた。

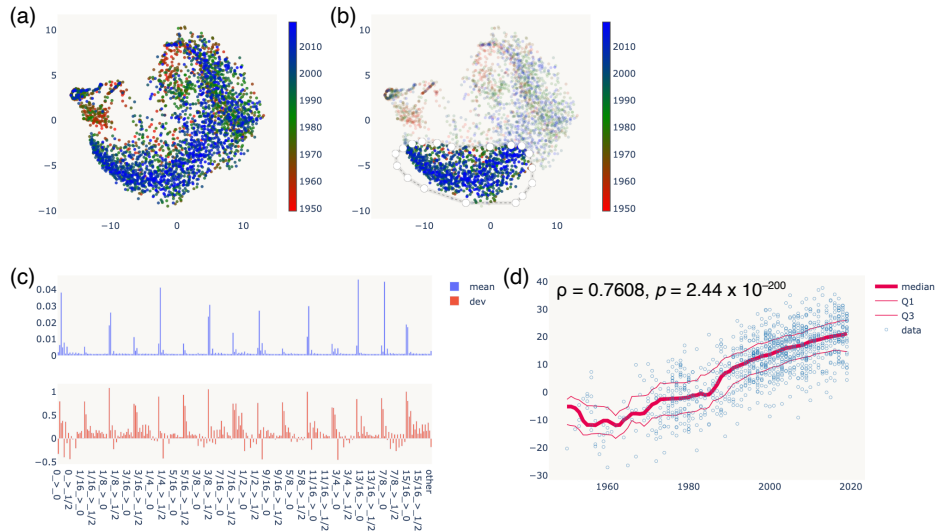


図4 (a) 拍節位置統計量データに対する概観パネル。16分音符リズムの領域の選択データに対する (b) 概観パネルと (c) 特徴量表示パネル, (d) 最適トレンド観察パネル。

HP2 $C \rightarrow C$ と $C \rightleftharpoons D$, $C \rightleftharpoons E$, $C \rightleftharpoons G$ に対しては $\tilde{\beta}_i = 1$, $A \rightarrow A$ と $A \rightleftharpoons G$, $A \rightleftharpoons E$ に対しては $\tilde{\beta}_i = -1$ (このトレンド方向を HP1 とは独立なものとするため $A \rightleftharpoons B$ は除外した), それ以外の音高クラス遷移に対しては $\tilde{\beta}_i = 0$.

3.1.4 仮説検証フェーズ

トレンド仮説 HP1 と HP2 に対する, 仮説的トレンド方向表示パネルと仮説的トレンド観察パネルを図 3(d)-(g) に示す。相関係数と p 値から, これらの仮説はどちらも統計的に有意であり, 特に HP1 の有意度が高いことが分かった。仮説的トレンド方向表示パネルでは, HP1 は 2 次元表現空間では右下から左上への方向に対応しており, HP2 は右から左への方向に対応していることが確認できた。従って, このデータでは 2 つの独立なトレンドの存在が明らかになった。HP1 と HP2 に対する仮説的トレンド観察パネルを比べると, これらのトレンドが異なる特性を持っていることが確認できる。HP1 の特徴量はおよそ 1965 年から 1985 年の間の時期に大きく増加しており, HP2 の特徴量はおよそ 1980 年から 1990 年の間の時期に増加している。前者のトレンドでは, 日本のポピュラー音楽におけるメジャー系音階の進化では, 一方の音階から他方の音階へと切り替わるという変化ではなく, HP1 の特徴の分布の漸次的な変化が起きたことが見てとれる。これは, 音楽文化の進化過程の興味深い性質を示している。

3.2 解析例 2: 16 分音符リズムの進化

3.2.1 特徴量の抽出

メロディーのリズムに関する作曲スタイルを表す特徴量として, 拍節位置のバイグラム確率を用いる。このバイグラム確率は, 各作品のメロディーデータ内の連続する拍節位置の遷移の同時確率であり, 拍節位置は 0 から 47 までの 48 種類存在するため, 48^2 次元の統計量である。解析では, 16 分音符単位の拍節位置の間の遷移とそれ以外の other 遷移に分けて考えて,

$16^2 + 1 = 257$ 次元の特徴量として扱う。以下, 拍節位置を小節の長さを 1 とした単位で表記する。例えば, $1/4$ は $4/4$ 拍子での 2 拍目, $15/16$ は小節内の最後の 16 分音符の位置を表す。

3.2.2 データ選択フェーズ

このデータの分布には, 3 つの大きなクラスターが存在することが概観パネルで確認できた (図 4(a))。左領域に分離したクラスターと右領域にある様々な時代のサンプルからなる密集したクラスター, そして, 下領域にある主に 1980 年代以降のサンプルから成るクラスターである。特徴量表示パネルを調べると, これらのクラスターは各々, other 遷移が多いリズムパターン (三連符や三拍子のリズムが含まれると考えられる) と 8 分音符リズム, 16 分音符リズムに対応することが分かった (図 4(b)(c))。また, 概観パネルから, 8 分音符リズムおよび other 遷移を多く含むリズムから 16 分音符リズムへの変遷 (つまり, 短いリズムの $4/4$ 拍子に向かう変化) に関わる全体的なトレンドの存在を予想することができる。以下では, 16 分音符リズム領域に含まれるより非自明なトレンドに注目した分析結果について述べる。

16 分音符リズム領域のデータサンプルを選択すると, 最適トレンド観察パネルは, サンプル数が多い期間である, 1990 年代から 2010 年代にかけての持続的なトレンドを示した (図 4(d))。また, この領域では 1970 年以前には少数のサンプルしかないことも確認できた。そこで, 時間スライダーを用いて 1990 年以降の期間のデータのみをさらに選択して, 以下の分析を行った。

3.2.3 仮説立案フェーズ

データ選択の後, 最適トレンド観察パネルでは相関係数が 0.73 の明確なトレンドが示された (5(b))。しかし, 重み β が最も大きいあるいは最も小さいバイグラムの要素は, 頻度が非常に小さいものであり, この結果から解釈可能なトレンド方向を見つけることは困難であった。さらに, PCA パネルにおい

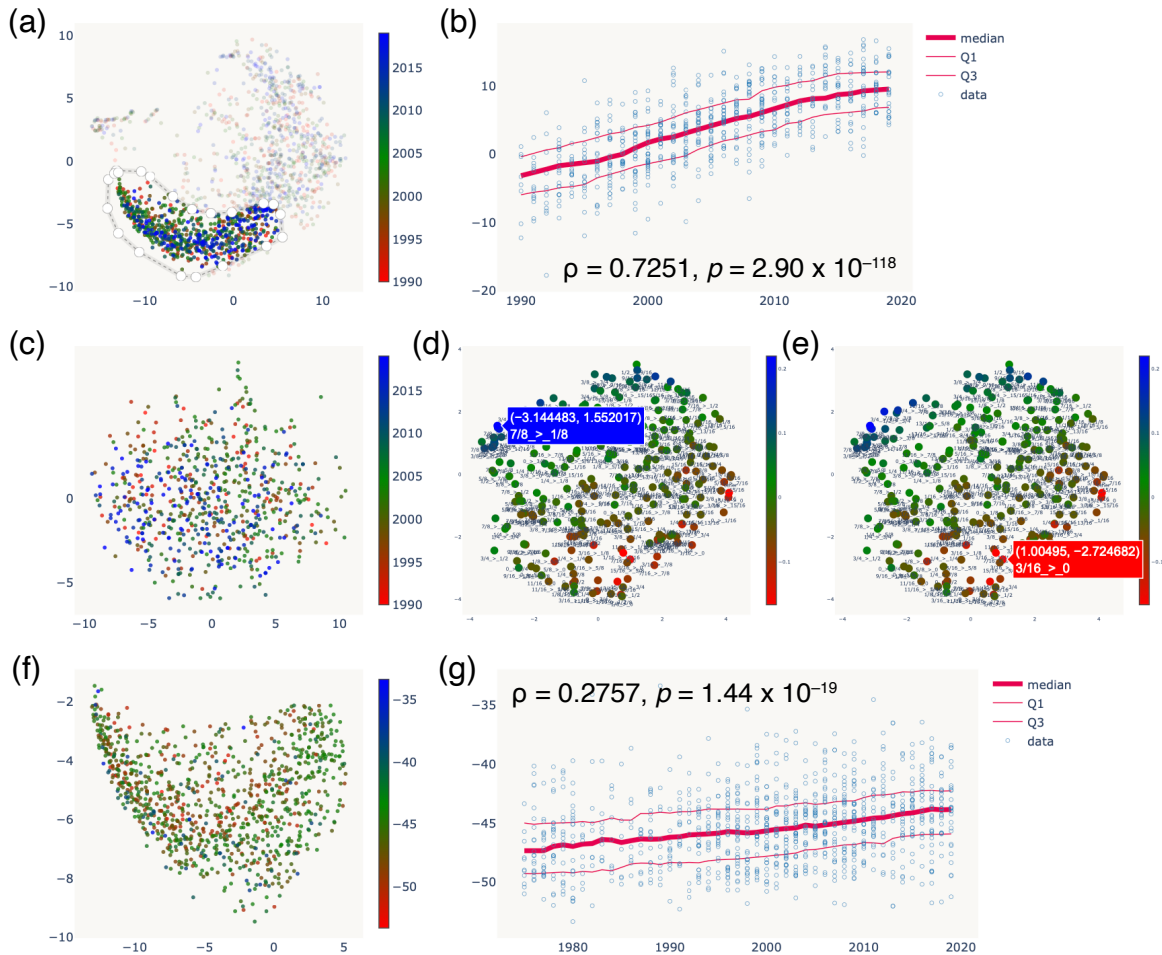


図 5 16 分音符リズムの進化解析におけるトレンド抽出で用いた可視化画面。

ては明確なトレンドは見つからなかった (図 5(c))。

そこで、解釈可能なトレンド仮説を探すために、次元散布図パネルを用いた (図 5(d)(e))。CTD の値が最大の 2 つのバイグラムは $7/8 \rightarrow 1/8$ と $3/8 \rightarrow 5/8$ であり、CTD が負の方向に最も小さかったバイグラムの多くは、0 (強拍) を含むものであった。この結果から、トレンドにはシンコペーションが関係しているという予想を立てた。シンコペーションとは、「前のめり」の感覚を表すリズムを意味し、強拍あるいは $1/2$ などの準強拍をまたぐ拍節位置の遷移として表される。この予想に基づき、解釈が容易なトレンド仮説を立てるため、強拍をまたぐ拍節位置遷移で短い音符を伴うもののみを考えることにした。これにより、次の仮説的トレンド方向 (HM1) を立案した。

HM1 $\{13/16, 7/8, 15/16\} \rightarrow \{1/16, 1/8, 3/16\}$ (9 種類) に対しては $\tilde{\beta}_i = 1$, $\{13/16, 7/8, 15/16\} \rightarrow 0$ (3 種類) に対しては $\tilde{\beta}_i = -1$, その他の遷移に対しては $\tilde{\beta}_i = 0$ 。

3.2.4 仮説検証フェーズ

図 5(f)(g) は、トレンド仮説 HM1 を検証した結果を示している。仮説的トレンド観察パネルでは、中程度だが有意な相関が確認され、シンコペーションの頻度の増加が選択データに含まれるトレンドの要因の一つであることが示された。仮説的トレンド方向表示パネルでは、HM1 特徴量は 2 次元表現空間の

上下方向に緩く対応することが示された。この解析例では、興味深くて非自明なトレンドの発見に、対面的なデータ表示を含む本研究の可視化手法が有効であることが示された。発見されたトレンドは 2000 年代以降にも継続しており、音高クラス特徴量が顕著なトレンドを示した期間とは異なることから、音楽学的にも興味深い現象と言える。

4 結 論

本稿では、時刻スタンプ付き高次元データから適切なデータ選択を行い、解釈可能なトレンドの特徴量方向の抽出を行うための対話的可視化手法について述べた。ユーザがデータの性質を理解しながら、トレンドの仮説の立案と検証ができる様に、種々の要素技術を組み合わせた、多面的なデータ可視化を含むシステムを実装し、音楽スタイル進化解析の具体例を通して、その有効性を示した。解析例を通して、理論的に最適なトレンドの推定は有用ではあるが、必ずしも解釈可能なトレンドの発見には直結しないこと、PCA を用いた表示もトレンドの発見に有用な場合とそうでない場合があること、また、PCA 表示が有用でない場合には特徴量の次元プロットが利用可能な場合があることなどが示された。これらは、本研究の手法の特徴である多面的なデータ表示の有効性を示すものであり、どのパネ

ルが有用であるかはデータに応じて変化するため、対話的操作の有効性も示すものである。

今後は、本研究の可視化ツールを汎用性の高い形でライブラリー化あるいはアプリケーション化した上で公開し、幅広い分野の研究に利用できるようにすることが課題である。また、創作物データに付与されることが多い、作者やジャンル、地理情報などのメタ情報を可視化要素に含めることで、データの理解と解釈可能なトレンドの発見をより容易にする技術的改善も取り組むべき課題である。さらに、絵画や文学を含む多様な文化領域のデータ解析や形態進化解析などの検証研究を行い、可視化手法のさらなる機能向上に向けた知見を深める研究も行う予定である。

謝 辞

本研究は、日本学術振興会科研費 21K12187, 21K02846, 22H03661 および JST 創発的研究支援事業 JPMJPR226X からの支援を受けて行われた。

文 献

- [1] Mauch, M., MacCallum, R. M., Levy, M. and Leroi, A. M.: The evolution of popular music: USA 1960–2010, *Royal Society Open Science*, Vol. 2, No. 150081, pp. 1–10 (2015).
- [2] Youngblood, M.: Conformity bias in the cultural transmission of music sampling traditions, *Royal Society Open Science*, Vol. 6, No. 191149, pp. 1–8 (2019).
- [3] Sigaki, H. Y. D., Perc, M. and Ribeiro, H. V.: History of art paintings through the lens of entropy and complexity, *Proceedings of the National Academy of Sciences of the USA*, Vol. 115, No. 37, pp. E8585–E8594 (2018).
- [4] Nakamura, E. and Saito, Y.: Evolutionary analysis and cultural transmission models of color style distributions in painting arts, *Proc. Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, pp. 493–500 (2023).
- [5] Brand, C. O. and Mesoudi, A. A. A.: Cultural evolution of emotional expression in 50 years of song lyrics, *Evolutionary Human Sciences*, Vol. 1, No. e11, pp. 1–14 (2019).
- [6] Klingenberg, C. P.: Evolution and development of shape: integrating quantitative approaches, *Nature Reviews Genetics*, Vol. 11, No. 9, pp. 623–635 (2010).
- [7] Interiano, M. et al.: Musical trends and predictability of success in contemporary songs in and out of the top charts, *Royal Society Open Science*, Vol. 5, No. 171274, pp. 1–16 (2018).
- [8] Nakamura, E. and Kaneko, K.: Statistical evolutionary laws in music styles, *Scientific Reports*, Vol. 9, No. 15993, pp. 1–11 (2019).
- [9] Singh, R. and Nakamura, E.: Dynamic cluster structure and predictive modelling of music creation style distributions, *Royal Society Open Science*, Vol. 9, No. 220516, pp. 1–18 (2022).
- [10] Chakrabarti, D., Kumar, R. and Tomkins, A.: Evolutionary clustering, *Proc. ACM International Conference on Knowledge Discovery and Data Mining (SIGKDD)*, pp. 554–560 (2006).
- [11] Blei, D. M. and Lafferty, J. D.: Dynamic topic models, *Proc. International Conference on Machine Learning (ICML)*, pp. 113–120 (2006).
- [12] Liu, S., Wang, B., Bremer, P.-T. and Pascucci, V.: Distortion-Guided Structure-Driven Interactive Explo-

- ration of High-Dimensional Data, *Computer Graphics Forum*, Vol. 33, No. 3, pp. 101–110 (2014).
- [13] Turkay, C., Filzmoser, P. and Hauser, H.: Brushing dimensions—a dual visual analysis model for high-dimensional data, *IEEE transactions on visualization and computer graphics*, Vol. 17, No. 12, pp. 2591–2599 (2011).
- [14] Sonali, P. and Kumar, D. N.: Review of trend detection methods and their application to detect temperature changes in India, *Journal of Hydrology*, Vol. 476, pp. 212–227 (2013).
- [15] Wang, C., Yu, H. and Ma, K.-L.: Importance-driven time-varying data visualization, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 14, No. 6, pp. 1547–1554 (2008).
- [16] Kumatani, S., Itoh, T., Motohashi, Y., Umezu, K. and Takatsuka, M.: Time-varying data visualization using clustered heatmap and dual scatterplots, *Proc. International Conference Information Visualisation (IV)*, pp. 63–68 (2016).
- [17] Van der Maaten, L. and Hinton, G.: Visualizing data using t-SNE, *Journal of Machine Learning Research*, Vol. 9, No. 11, pp. 2579–2605 (2008).