

絵画芸術における色彩スタイルの文化進化モデルに基づく創作者の影響度推定

中 村 栄 太[†](正会員) 齋 藤 康 之^{††}(正会員)

[†]京都大学, ^{††}木更津工業高等専門学校

Estimation of Creator Influences Based on Cultural Evolution Models of Color Styles in Painting Arts

Eita NAKAMURA[†](*Member*), Yasuyuki SAITO^{††}(*Member*)

[†]Kyoto University, ^{††}National Institute of Technology, Kisarazu College

〈あらまし〉 本研究では、絵画芸術における色彩スタイルの進化ダイナミクスと文化伝達について議論する。視覚芸術などの創作文化は、知識の伝達と変形の過程を通じて発展し、創作者間の知識伝達の構造が顕著な進化の規則性を生み出すことがある。最近の研究では、絵画の進化における興味深いトレンドと動的なパターンが見つかるが、これらのトレンドと文化伝達過程との関係は十分に理解されていない。本研究では、まず、クラスタリング手法を適用して、油絵の色彩分布の時代変化を分析する。その結果、色彩スタイルのクラスターの一部には同期した頻度変化が現れた。これらの頻度変化の同期性が、各々偏ったクラスターに属する絵画を制作する創作者の存在と関連することを示す。次に、色彩スタイルが創作者間で文化伝達される過程を表すモデルを構築し、色彩スタイルが主に1人の創作者から伝達される、影響者主導型のモデルが歴史的データを特に良く説明できることを示す。さらに、このモデルを用いた教師なし学習に基づいて、画像データのみから創作者の影響度を推定する方法を導出し、美術史でよく知られる創作者を高い精度で推定可能であることを確認する。

キーワード：絵画の色彩分析, 創作知識の文化伝達, 文化進化モデル, 教師なし学習

<Summary> We study the cultural transmission and evolutionary dynamics of color styles in painting arts. Creative cultures such as visual arts develop through the processes of knowledge transmission and modification, where the structure of knowledge transmission among creators may lead to notable patterns of evolution. Recent research has discovered interesting trends and dynamic patterns in the evolution of painting, but the relationship between these trends and the process of cultural transmission is still poorly understood. Here, we apply a clustering method to analyze the temporal changes in color distribution in oil paintings. As a result, synchronous frequency changes appear in some clusters of color styles. The synchronicity of these frequency changes indicates the existence of creators who produce paintings belonging to a biased set of clusters. Next, we construct a model representing the process of cultural transmission of color styles and demonstrate that an influencer-guided model, where color styles are primarily transmitted from one creator, explains historical data well. Furthermore, using this model, we derive a method for estimating the influence of creators solely from image data. We confirm that creators estimated to have high influence align to a notable extent with those frequently mentioned in the literature on art history.

Keywords: painting color style, cultural transmission of creation knowledge, cultural evolution model, unsupervised learning

1. はじめに

近年、生成 AI^{1)~3)}の進歩により、絵画などの芸術分野における画像処理の応用が注目されている。機械学習に基づく自動生成手法により、多様なスタイルの画像生成が可能となったが、この方法は学習に用いる、人が作成した歴史的な絵画

の画像データの蓄積量やジャンルに大きく依存している。一方で、新しい創作スタイルの絵画を生成することは依然として大きな課題となっている⁴⁾。実際のところ、人が新しい創作スタイルを生み出す過程についての定量的で科学的な理解はまだ限定的である。人間のこの創造的知能を理解できれば、現在のシステムよりもはるかに多様なスタイルの絵画が自動

生成できる技術の実現につながると期待される。

創作文化は、創作に関する知識の伝達と変形・創出を繰り返しながら進化している。このような文化伝達過程を含む文化進化は、生物進化との理論的類似性に基づいて研究されており、一般的に環境要因と動力学的要因の二つが進化過程を形作ると考えられている⁵⁾。環境要因とは、選択圧を生み出す様々な要因を指し、進化の方向と制約を決定する。絵画文化の場合、人々の選好や画材の供給状況、経済や政治などの社会背景が含まれる。一方、動力学的要因は、知識の伝達、変形、選択の過程によって起こる効果を指し、一般に進化の速度や規則性を理解する上で重要である。

近年、大規模な電子データの活用や深層学習などの解析技術の発展により、西洋美術を中心とした絵画データの進化解析に関する研究が盛んになっている⁶⁾。従来研究では、物理系の解析で使用されるエントロピー・複雑性の特徴量⁷⁾や畳み込みニューラルネットワーク (CNN) によって抽出された特徴量^{8),9)}の分析により、時代ごとのトレンドの存在が示された。また、色のコントラストの分析から、特に 15 世紀から 16 世紀と 19 世紀後半に、絵画の平均的特徴に大きな変化があったことが示され、これらは各々、油絵具の普及と絵画スタイルの個人性の増加に関連付けられている¹⁰⁾。数世紀にわたるトレンドや、急速な変化を伴う革命期の存在は、音楽データでも確認されている^{11)~14)}。これらの結果は、絵画スタイルの時間変化と社会的な環境要因との関係を明らかにした。しかし、文化の伝達による動力学的要因が芸術進化に及ぼす影響については、まだ十分に理解されていない。

本研究では、作者が通常、複数の創作スタイルの作品を制作するという事実に注目し、分布として表される創作スタイルの文化的伝達と絵画の進化について調べる。まず、油絵の色彩スタイルをクラスター分析し、クラスター頻度と同期的な変化を見出す。この同時性には各作者の色彩スタイル分布が持つ性質が強く関係していることが示されている¹⁵⁾。

次に、作者が自身の色彩スタイル分布を選択する過程を理解するために、この分布が作者間で伝達される過程を含む文化進化モデルを構築する。これにより、理論モデルに基づく創作知識の伝達過程の分析、具体的には、作者の影響度をデータから推定することが可能になる。文化伝達においては、一般には様々な知識伝達の形態が考えられるが、ここでは、各作者に対して主に 1 人の先行の作者が伝達に関与する影響者主導型伝達のモデルを考える。統計的推論に基づき、本モデルが過去のデータの統計的性質を近似的に捉えられることを示す。さらに、推定された影響度の高い作者のリストと美術史文献に登場する作者のリストの一致度を測定することで、本モデルによる画像データから作者の影響度の推定手法の有効性を検証する。本研究の分析手法は、創作物データから抽出した統計量を扱う点で、音楽データに関する先行研究¹⁴⁾と共通するが、創作者間のミクロな知識参照を扱う点で新しく、他の文化領域にも適用可能な枠組みである。




図 1 データ分析の流れ。(a) 色彩統計量を抽出する処理、(b) 色彩スタイルクラスターと作者のスタイル分布

Fig. 1 Flow of data processing. (a) Extraction of color statistics and (b) color style clusters and creator's style distribution

2. 色彩スタイルのクラスター分析

2.1 データと分析方法

本研究では、公開ウェブサイト WikiArt.org から取得した主に西洋絵画の画像データを使用する。取得した画像データには、制作年、作者、素材などのメタデータが関連付けられている。分析に用いるのは、油絵を表す「oil」の素材ラベルを持つ 32 401 点の作品であり、作品の制作年は 1270 年から 2022 年までの範囲に分布し、作者の総数は 1128 であった。

以下の手順で各画像から色彩統計量を抽出した (図 1)。まず、データ分析の計算コストを低減するため、すべての画像をダウンサンプリングにより 100 × 100 ピクセルに変換する。次に、グレースケールにおいて等間隔の 4 色 (輝度値) と円錐形の HSV 色空間内で等間隔に配置された 36 色から成る $I = 40$ 個の代表色を用いた減色処理を行う (図 1(a))。さらに、各作品 n における代表色 i の相対頻度 $\theta_n = (\theta_{ni})_{i=1}^I$ を計算する。以下の分析には、作者 a_n 、制作年 t_n 、色彩統計量 θ_n の組 (a_n, t_n, θ_n) を用いる。

創作スタイルの進化を定量的に調べるため、色彩統計量の分布の時間変化を分析する。高次元の統計量を扱うため、まず統計量の空間でクラスタリングを適用して、データ点が密集したいくつかの領域を特定する (これらを色彩スタイルクラスターと呼ぶ)。具体的には、次の様に定義される離散分布混合モデルをクラスタリングに使用する。

$$P(\theta_n) = \sum_{k=1}^K \pi_k P(\theta_n | \bar{\theta}_k) \quad (1)$$

ここで、 K はクラスターの個数、 π_k はクラスターの確率 (混




図2 色彩相対頻度の時間変化
Fig. 2 Evolution of color frequencies

合確率と呼ぶ), $\bar{\theta}_k$ はクラスター k の平均統計量を表す. 各クラスター k の離散分布モデル $P(\theta_n|\bar{\theta}_k)$ は次で定義される.

$$P(\theta_n|\bar{\theta}_k) = \prod_{i=1}^I \bar{\theta}_{ki}^{L\theta_{ni}} \quad (2)$$

ここで, L は確率を計算するためのサンプル数に対応する補助パラメーターである. このクラスタリングのアルゴリズムは, EM アルゴリズム¹⁶⁾に基づいて導出できる. E ステップでは, 事後確率は $P(k|n) \propto \pi_k P(\theta_n|\bar{\theta}_k)$ として計算される. ここで, L は $L = 10t$ (t は反復時刻を表す) として設定し, これは, 焼きなまし法の逆温度と同様な機能を持つ. M ステップでは, 混合確率を $\pi_k \leftarrow \sum_n P(k|n)$ として更新し, 平均統計量は $\bar{\theta}_{ki} \leftarrow \sum_n P(k|n)\theta_{ni}$ として更新する. このクラスタリングは, 時間情報 t_n を用いずに行う. EM アルゴリズムの収束の後, 各作品 n を最尤のクラスター $k_n = \operatorname{argmax}_k P(k|n)$ に割当て, 以降の分析に用いる.

2.2 クラスタ分析の結果

1450 年以前に制作された作品は少量であったため, 1450 年以降を分析の時間範囲とした. 図2は, 色の相対頻度の時間変化を示している. 相対頻度は 25 年の区間ごとに計算しており, プロット線は対応する代表色で描写している (10^{-2} 付近の白線と薄黄線は影を付けて示している). 最も頻繁に使用される色は明度と彩度が低いものである一方で, 明るくて彩度が高い色は一般に稀であることが見て取れる. この図では, 文献 15) で議論されているように, いくつかのトレンドが確認できる. これらの全体的なトレンドは各時代における全体的な変化を表しているものの, 時代ごとの平均頻度は作品ごとの色の組合せの変動や偏りを表すことができない. それに対し, 以下に結果を示すとおり, クラスタに基づく分析方法はこの問題を解決し, 背後にある進化過程を調べるために有用である.

色彩統計量のクラスタリングの結果を図3に示す. ここでは, 分布を近似するために $K = 20$ 個のクラスターを使用した. 図中の上のパネルは各時代の作品数を示している. はじめの数世紀間に主に使われたクラスターでは, 主に暗い色の組合せが用いられていることがわかる. 一方, 19 世紀以降




図3 スタイルクラスターの平均統計量及び相対頻度の時間変化
Fig. 3 The mean statistics and the evolution of relative frequencies of the style clusters

により頻繁に使われたクラスターでは, 明るい色を多く含む色の組合せを用いるものが多い. 図3より, 色彩スタイルクラスターの相対頻度の変化において, 特記すべきいくつかの特徴が読み取れる. 第一に, 各時代で複数のクラスターが活発化しており, 活発なクラスターは時間の経過とともに徐々に変化する, 共時的かつ過渡的なクラスター構造^{12),17)}が観察できる. 常に複数の活発なクラスターが存在することは, 複数の芸術スタイルやジャンルが共存していることを表している. 第二に, 複数のクラスターが出現した顕著な時期が2つある. 15 世紀から 16 世紀にかけてと, 19 世紀半ばから 20 世紀半ばにかけてである. これらの時期は, 色のコントラストが大きく変化した時期を示す先行研究の結果¹⁰⁾と一致している. 第三に, 出現と衰退の時期が同期しているクラスターがいくつか確認できる. 例えば, クラスター 1 と 3, 及びクラスター 17 と 18 は, 各々, 同期的な頻度の上昇を示している. これらの結果は, 色彩スタイルの進化における巨視的な規則性の存在を示していると考えられる.

2.3 作者の色彩スタイル分布の偏りと共有性

スタイルクラスターの頻度変化に見られる同期性を理解するため, 文献 15) では, この同期性と, 各作者 a の作品におけるクラスターの相対頻度 $\pi_a = (\pi_{ak})_{k=1}^K$ (これを作者の色彩スタイル分布と呼ぶ) との関係が分析された. もし, 各時代における作者のスタイル分布に偏り (特定のいくつかのクラスターに分布が局在していること) と共有性 (同時代の作者間で似たスタイル分布が共有されること) があるとする, 異なるスタイルクラスター間の頻度変化には相関が生まれると考えられる. 文献 15) では, 作者のスタイル分布を介したスタイルクラスター間の関係性をネットワークを用いて分析しており, この仮説が実際にデータから支持されることが示された. つまり, 作者のスタイル分布には偏りと共有性が見られ, 個々の作者のこれらの性質が, クラスタ頻度の

同期性という、色彩スタイルの進化における全体的な規則性が生じる大きな要因の一つになっていることが示された。

3. 色彩スタイル分布の文化進化モデル

3.1 作者のスタイル分布の文化進化モデル

前章で説明したとおり、作者の色彩スタイル分布には偏りと共有性が存在する。こうした構造が生じる原因として、作者間での創作知識の文化伝達の影響が考えられる。絵画芸術に関する複雑な知識は通常、他の作者やその作品から学習されるため、色彩スタイル分布がこの学習過程で伝達されるという可能性が考えられる。また、後世における影響度の高い作者のスタイル分布がより多くの作者によって学習されることで、共有性が生じると期待される。この他にも、教会やパトロンからの需要などの社会的要因も考えられるが、ここでは単純な仮定として、文化伝達の可能性を調べる。

以下では、具体的な文化伝達の過程を組入れた文化進化の数学モデルを構築する。これにより、作者の影響度や作者が影響を受けた作者をデータから推定することが可能になる。文化現象においては、遺伝子の進化とは異なり、文化的親の数は1人（無性）または2人（有性）の場合に限定されず、可変な数の文化的親からの伝達が可能である。以下で考える、影響者主導型伝達モデルでは、各作者は主に、師匠のような特定の1人の先行の作者（影響者）の作品から自分の創作スタイルを学習すると仮定する。これは幅広いモデルの可能性の中で極端な場合を表している。なお、文献 15) では、各作者が、ある創作スタイルのコミュニティに属する多数の作者の作品から創作スタイルを学習すると仮定する、もう一方の極端なモデル（コミュニティ主導型伝達モデル）も調べられたが、影響者主導型伝達モデルの方がデータをより良く説明できることが示された。

以下の文化進化モデルは、伝達・変異・選択過程の確率的記述に基づく定式化によるものである⁵⁾。これは、集団遺伝学で用いられる生物進化のモデル¹⁸⁾に似た定式化であるが、過去の作者の影響は原理的にその死後も長期間継続することができる点異なる。作者 a が創作を開始した年を t_a^s で表す。これはデータ内の作者の作品の最初の年として定義される。また、作者 a の作品におけるスタイルクラスターの頻度（回数）を $\tilde{\pi}_a = (\tilde{\pi}_{ak})_{k=1}^K$ で表す。これらの頻度を正規化することにより、スタイル分布 π_a が得られる。さらに、 t 年以前に制作された作者 a の作品から得られたスタイル分布を $\pi_a^{<t}$ によって表す。本モデルは、全ての作者 a に対する確率分布 $P(\tilde{\pi}_a)$ を明示的に記述するものとして定式化される。

3.2 影響者主導型伝達モデル

本モデルでは、学習をする各作者は先行の作者の中から影響者となる作者を1人選び、そのスタイル分布を学習する。このモデルは次の式で表される。

$$P(\tilde{\pi}_a) = \sum_{a': t_{a'}^s < t_a^s} P_{\text{sel}}^{t_a^s}(a') P_{\text{dis}}(\tilde{\pi}_a | \pi_{a' \rightarrow a}) \quad (3)$$

ここで、総和は $t_{a'}^s < t_a^s$ を満たす全ての影響者の候補 a' に渡って計算され、 $P_{\text{sel}}^{t_a^s}(a')$ は作者 a に対する影響者 a' の選択確率、 $\pi_{a' \rightarrow a}$ は a' から a に伝達されるスタイル分布を表し、最後の因子は次の離散確率分布で与えられる。

$$P_{\text{dis}}(\tilde{\pi}_a | \pi_{a' \rightarrow a}) = \prod_k [\pi_{(a' \rightarrow a)k}]^{\tilde{\pi}_{ak}} \quad (4)$$

選択確率では、以下で説明する2つのバイアス項により学習者の傾向を表す。これらは、科学論文の引用ダイナミクスのモデル¹⁹⁾に用いられるバイアスと同様のものである。

1つ目のバイアスは新近性バイアスと呼ばれ、より最近に活躍した作者を影響者として選択する可能性が高いという傾向を表す。このバイアスは、時間間隔 $t_a^s - t_{a'}^s$ に依存する時間減衰重み $\mathcal{D}(t_a^s - t_{a'}^s; \tau_c)$ で表せる（ここで、作者時定数 τ_c はこのバイアスの時間スケールを表す）。時間減衰の具体的な関数形としては、以下の2つの可能性が考えられる。

$$\mathcal{D}(\Delta t; \tau) = \begin{cases} e^{-\Delta t / \tau} & (\text{指数関数型}) \\ 1/(\Delta t)^\alpha = e^{-\ln \Delta t / \ln \tau} & (\text{べき関数型}) \end{cases} \quad (5)$$

ここで、後者のモデルでは $\tau = e^{1/\alpha}$ ($\alpha = 1/\ln \tau$) として時定数を定義しており、表記の簡便化のため、両者のモデルにおいて定義の異なる時定数を同じ記号で表していることに注意されたい。指数関数型の時間減衰の場合は、時間間隔が時定数程度より大きくなると、重みが急激に小さくなるのに対して、べき関数型の場合は、時定数よりも大きな時間間隔に対しても減衰が緩やかであるという違いがある。

2つ目のバイアスは、影響者の（固有の）影響度（適応度とも呼ばれる）であり、影響者として選択される確率の中で、名声や知名度などに起因する、時間に依存しない成分を表す。ここで、各作者に対して影響度パラメーター $v_{a'}$ を導入する。また、潜在的な影響者 a' は少なくとも N_{bound} 個の作品を制作している必要があると仮定する（具体的には、 $N_{\text{bound}} = 7$ と設定する）。以上により、選択確率は次の式で与えられる。

$$P_{\text{sel}}^{t_a^s}(a') \propto \mathbf{I}(t_{a'}^s < t_a^s) \mathbf{I}(N_{a'}^{<t_a^s} \geq N_{\text{bound}}) \mathcal{D}(t_a^s - t_{a'}^s; \tau_c) e^{v_{a'}} \quad (6)$$

ここで、条件 C が真の場合は $\mathbf{I}(C) = 1$ 、そうでない場合は $\mathbf{I}(C) = 0$ であり、 $N_{a'}^{<t}$ は t 年以前に作者 a' によって制作された作品の数を表す。

伝達されるスタイル分布 $\pi_{a' \rightarrow a}$ は、影響者のスタイル分布 $\pi_{a'}$ に変異を含む変形が加わったものを表す。ここで、学習する作者が、影響者以外の作者の多くの作品を観察し、その時代の平均的なスタイル分布からの影響を受ける可能性も含めて考える。この状況は次の様に定式化できる。

$$\pi_{a' \rightarrow a} = (1 - \eta - \epsilon) \pi_{a'}^{<t_a^s} + \eta \pi^{<t_a^s} + \epsilon \mathbf{1}/K \quad (7)$$

ここで、 $\pi^{<t^s}_a$ は時刻 t^s_a (の直前) における平均スタイル分布を表し、 $\mathbf{1}/K = (1/K, \dots, 1/K)$ は一様分布であり、 η と ϵ は非負の定数である。右辺の第1項、第2項、第3項は各々、影響者からの伝達、その時代の平均的なスタイル分布からの伝達、ランダム変異を表している。平均スタイル分布 $\pi^{<t}$ は、新近性バイアスも組み込まれた形で、次の様に定義される。

$$\pi_k^{<t} \propto \sum_{n:t_n < t} \mathbf{I}(t_n < t) \mathbf{I}(k_n = k) e^{-(t-t_n)/\tau_p} \quad (8)$$

ここで、総和は t より前に制作された全ての作品 n に渡って計算され、 k_n は作品 n に割り当てられたクラスター、 τ_p は作品に対する時定数を表している。パラメーター η 及び ϵ は、式 (7) の第2項と第3項の強度を表し、各々、斜行伝達係数及びランダム変異率と呼ぶ。なお、式 (6) と (8) の中の時間減衰項は、時間の経過とともに過去の作者や作品の影響度を減少させることに注意されたい。また、これらの式における時間の制約により、確率 $P(\tilde{\pi}_a)$ の定義に将来の情報が使われないという因果的制約が守られている。

3.3 モデルパラメーターの推論法

創作知識の実際の伝達過程を観測することは難しいが、前節に述べたモデルのパラメーターは創作物データから教師なし学習の方法により推定できる。まず、本モデルは確率分布 $P(\tilde{\pi}_a)$ の記述として定式化されており、以下に示す、作品の総数で正規化された対数尤度が定義できる。

$$\mathcal{L}_{\text{tot}} = \left(\sum_a \ln P(\tilde{\pi}_a) \right) / \left(\sum_{a,k} \tilde{\pi}_{ak} \right) \quad (9)$$

また、これに指数関数を適用して得られる量 $\exp(\mathcal{L}_{\text{tot}})$ は多様度と呼ばれ、選択されるスタイルクラスターの実効的な個数として解釈できる。この量が小さいほど、モデルの予測性が高くなる。対数尤度 $\mathcal{L}_{\text{tot}}$ の値はモデルパラメーターに依存しており、最尤推定法では、これを最大化するようにモデルパラメーターを推定できる。ただし、変異率 ϵ と作品時定数 τ_p は、実質的に平滑化定数であり、これらの値は尤度に大きな影響を与えない。そこで、 $\epsilon = 10^{-6}$ と $\tau_p = 20$ 年に固定して考える。以下では、他のモデルパラメーターを推定するための具体的な方法について説明する。

推定対象のモデルパラメーターは $\{v_a\}$ 、 τ_c 、及び η である。これらのパラメーターを最適化するために反復法を適用する。つまり、1つのパラメーター（セット）を更新する際には、他のパラメーターは固定しておく。パラメーター τ_c と η については、グリッドサーチにより直接 $\mathcal{L}_{\text{tot}}$ を最適化することで推定できる。影響度 v_a については、影響者変数 a' を各学習者 a に対する潜在変数として扱うことで、EM アルゴリズムが適用できる。更新前のパラメーターセットを $\theta' = \{v'_a\}$ 、更新後のパラメーターセットを $\theta = \{v_a\}$ とおくと、EM アルゴリズムは以下の更新式で表される。

$$v_a \leftarrow \ln \left[\frac{\sum_a \phi_a(\tilde{a}|a, \theta')}{\sum_a P_{\text{sel}}(\tilde{a}; a, \theta) e^{-v_a}} \right] \quad (10)$$

表 1 進化モデルにおける多様度とパラメーターの推定値
Table 1 Perplexities and estimated parameters for the evolutionary models

時間減衰	多様度	τ_c (年)	η
指数関数	15.6	117	0.36
べき関数	15.6	4.51	0.36
(ランダムモデル)	19.1	NA	NA

ここで、 $P_{\text{sel}}(\tilde{a}; a, \theta)$ は式 (6) を表しており、事後確率を表す $\phi_a(\tilde{a}|a, \theta')$ は次式を用いて計算できる。

$$\phi_a(\tilde{a}|a, \theta) \propto P_{\text{sel}}(\tilde{a}; a, \theta) P_{\text{dis}}(\tilde{\pi}_a | \pi_{\tilde{a} \rightarrow a}) \quad (11)$$

このアルゴリズムは、標準的な方法¹⁶⁾で導出できる。

4. 文化進化モデルの性能評価と作者の影響度推定

4.1 尤度基準によるモデルの性能評価

前章に示した文化進化モデルの妥当性を評価し、新近性バイアスを表す時間減衰の関数形の比較を行うため、最尤推定により得られたモデルの予測性能を多様度を用いて評価した。この際、作者時定数 τ_c 及び斜行伝達係数 η は相対誤差が約1%の分解能で推定した。比較として、各作者 a が時代ごとの平均スタイル分布 $\pi^{<t^s}_a$ にしたがってクラスター頻度 $\tilde{\pi}_a$ で作品を生成するランダムモデルでの多様度も評価した。このモデルは、 $P(\tilde{\pi}_a) = P_{\text{dis}}(\tilde{\pi}_a | \pi^{<t^s}_a)$ により表される。

表 1 の結果から、ランダムモデルと比較して、進化モデルによる多様度は小さい値を示しており、文化伝達のモデルがデータの予測に大きく寄与することがわかる。また、2種類の時間減衰モデルの比較では、多様度に有意な差異は認められず、尤度基準ではどちらのモデルも同等の予測性能を示すことがわかった。一方で、最尤推定で得られた作者時定数 τ_c の値は、これら2つの場合で異なることも示された。指数関数型減衰モデルにおける時定数の推定値 $\tau_c = 117$ 年は、過去の作者の影響が比較的長期間持続することを示している。べき関数型減衰モデルでは、推定値は $\tau_c = 4.51$ 年と小さいが、これは、同じ時定数の値でもべき関数型モデルの方がより緩やかな時間減衰を表すことが理由だと考えられる。最尤推定で得られた斜行伝達係数の値は、どちらのモデルでも等しく、 $\eta = 0.36$ であった。この比較的大きな値は、色彩スタイル分布が1人の影響者だけでなく、他の作者からも学習されていることを示している。

4.2 作者の影響度推定の性能評価

進化モデルにより推定される各作者の影響度は、直接観測可能な量ではないため、以下の方法で間接的な評価を行った。この評価は、もし進化モデルが現実の作者の影響度を推定できるとすると、高い推定影響度を持つ作者のリストは、美術史で頻繁に取り上げられる著名な作者のリストと良く一致するはずであるという仮定に基づく方法である。具体的には、まず、進化モデルにより推定された影響度の高い順からソート




図 4 推定影響度の高い作者のリスト（指数関数型減衰モデルの結果）とゴンブリッチの作者リスト²⁰⁾の一致度
 Fig. 4 Degree of match between the estimated list of influential creators and the Gombrich's list²⁰⁾

した作者のリストを作成した。次に、美術史で頻繁に取り上げられる作者のリストを得るため、美術史の古典的文献であるゴンブリッチの著書²⁰⁾に登場する作者のリストを作成した。文献 20) に記載されている作者のうち、絵画の分野で主な活動をしていない数名を除き、101 名の作者からなるリスト U_G （ゴンブリッチのリストと呼ぶ）を抽出した。これらのリストの一致度を計算するため、二項分類の評価尺度として一般的である F 値を用いる。モデルの推定結果のリストの先頭から、あるサイズ M のリスト U_M を切り出し、適合率 $P_M = \#(U_M \cap U_G) / \#U_M$ 、再現率 $R_M = \#(U_M \cap U_G) / \#U_G$ 、及び F 値 $F_M = 2P_MR_M / (P_M + R_M)$ を計算した。様々な M に対して、F 値が高い値を示すとき、モデルによる作者の影響度の推定精度は高いとみなせる。また、ゴンブリッチのリストを正解とみなして、それ以外の作者がリスト U_M になるべく含まれないことが好ましい状況では、適合率が高いモデルが良いモデルとみなされる。なお、ランダムに並べ替えた作者のリストに対しても同様の計算を行うことで、チャンスレートによるベースライン比較が可能である。

指数関数型の時間減衰モデルの場合に、最尤推定により得られた進化モデルに対する評価結果を図 4 に示す（三角印は極大 F 値の位置を示している）。進化モデルによる F 値曲線が、チャンスレートよりも大幅に高い値を示していることから、モデルによる作者の影響度推定の有効性が確認できる。この結果は注目値するが、より短い時定数 $\tau_c = 50$ 年とより小さい斜行伝達係数 $\eta = 0.1$ を用いて推定した影響度を用いた場合、F 値曲線はさらに高い値を示すことがわかった（図 4）。これは、尤度基準と「著名な」作者の推定精度の各々に対して、最適な τ_c と η の値が異なることを意味する。

作者の影響度推定の観点で最適なモデルパラメーター（ τ_c と η ）の値を求めるため、これらの値に対する評価尺度の依存性を調べた。評価尺度としては、F 値曲線の極大点に対応する極大 F 値 $F_{\max} = \max_M F_M$ 、 $M = 25$ のときの適合率 $P_{M=25}$ 、及び多様度を測定した。図 5 に示す結果では、各パネル上で評価値が最も良い点を太枠で示し、その評価値を隣に記している。両方の時間減衰モデルの場合において、極大




図 5 作者時定数 τ_c と斜行伝達係数 η に関する進化モデルの性能尺度の依存性
 Fig. 5 Dependence of evaluation metrics on τ_c and η




図 6 極大 F 値のクラスター数 K に対する依存性
 Fig. 6 Dependence of the maximal F score on the number of clusters K

F 値や適合率 P_{25} が最適な点では、最尤推定パラメーターに比べて τ_c 及び η が小さい値を持つことがわかる。また、これらの最適な点における極大 F 値と P_{25} は、指数関数型の時間減衰モデルの方がべき関数型のモデルに比べて、若干高い値を示している。このことから、作者の影響度推定においては、指数関数型の方が若干優れていると示唆される。なお、図 5 からは、最尤な点の周りで作者時定数と斜行伝達係数の値が尤度に与える影響は比較的小さいこともわかる。

また、以上の分析ではスタイルクラスターの数を固定してきたが、クラスター数 K を変化したときの極大 F 値の振る舞いを図 6 に示す。この図は指数関数型減衰モデルの結果を示しており、各 K に対して最尤推定で得られたモデルパラメーターを用いて推定した作者の影響度に基づいている。この結果では、極大 F 値は $K = 20$ 付近で最大となっており、創作者の影響度を推定する上で $K = 20$ は最適なクラスター数に近いことが示された。以下では、引き続き $K = 20$ とした場合の結果について述べる。

表 2 指数関数型の時間減衰を持つ文化進化モデル ($\tau_c = 50$ 年, $\eta = 0.1$) により推定された最も影響度の高い作者 25 人のリスト

Table 2 Most influential creators estimated by the ($\tau_c = 50$ yrs, $\eta = 0.1$)

影響度 e^{v_a}	作者 a	制作開始年 t_a^s	作品数
1.81	レイセルベルヘ	1880	125
1.77	アイヴァゾフスキー	1835	238
1.75	デ・フリーヘル	1629	29
1.70	ティツィアーノ	1503	200
1.63	ロラン	1630	62
1.62	エルナンデス	2001	17
1.60	テニールス (子)	1633	54
1.58	ベッリーニ	1455	56
1.57	ハフトカ	1986	8
1.54	ルノワール	1858	913
1.53	ホフマン	1902	16
1.48	ブーシェ	1734	51
1.45	マレーヴィチ	1904	113
1.44	ピカソ	1893	499
1.44	ベラスケス	1616	127
1.43	ゲインズバラ	1745	125
1.43	ファン・エイク	1426	63
1.42	リキテンスティン	1961	26
1.42	モネ	1861	191
1.41	マティス	1890	188
1.40	ゴッホ	1881	747
1.38	コロー	1825	409
1.38	ゴーギャン	1873	460
1.38	アルトドルファー	1507	25
1.37	ブイノフスキ	2001	9

4.3 作者の影響度の推定結果

この節の分析では、図 5 において適合率 $\mathcal{P}_{25}$ が最大で極大 F 値も高い、パラメーター $\tau_c = 50$ と $\eta = 0.1$ を持つ指数関数型の時間減衰を含む進化モデルを用いている。このモデルによる推定影響度が最も高かった 25 人の作者のリストを表 2 に示す (ゴンブリッチの文献 [20] に登場する作者の名前は太字で示されている)。このリストには、様々な時代に活躍した作者が含まれていることがわかる。そして、リストにはデータセット内の作品数が比較的少ない作者も含まれており、その中にはデ・フリーヘル、ホフマン、リキテンスティンなどの著名な作者が含まれる。この結果は、作者の名声とデータ内の作品数には高い相関があるものの、モデルがデータ内の作品数による単純な推定ではなく、色彩スタイルの特徴に基づいて影響度を推定していることを示す点で重要である。この結果が純粋な画像データ及び因果的制約を課すために使われた制作年に関するメタデータのみから得られたことは、定量的かつ客観的な方法による絵画芸術の進化分析に本モデルが有効であることを示している。

本モデルを用いて、式 (11) の事後確率を最大化することで、各作者に最も影響を与えた作者を推定することができ、これから創作知識の参照ネットワークが推定できる。例として、図 7(a) に示す結果では、ピカソとマティスがゴッホにネットワーク内でつながっていることが確認できる。この結果の妥




図 7 進化モデルにより推定された知識参照ネットワーク. (a) ネットワークの全体図及びゴッホにつながっている部分の拡大図, (b) 5 名の著名な作者の間のネットワークについて、推定結果と WikiArt 及び日本語版 Wikipedia に基づく結果で比較した結果

Fig. 7 Knowledge reference network inferred by the model. (a) The whole network and an enlarged part including creators connected to V. van Gogh, (b) the estimated network for five famous artists, compared to the reference networks obtained from the information on WikiArt and Wikipedia (Japanese) pages

当性を調べるために、WikiArt.org 及び日本語版 Wikipedia の作者ページに掲載されている作者間の影響の有無に関する情報を参照ネットワークとして表したものを図 7(b) に示す (矢印は参照元から参照先に向けて描いている)。この比較結果から、推定結果の参照構造は美術史における知見のある程度反映していることが確認できる。一方で、WikiArt と Wikipedia の情報では、作者間の参照関係は異なっており、美術史の知見においても不確実性が大きいことがわかる。また、本研究の手法では扱っていない、2 人以上の影響者への参照や相互参照が一般にはあることがわかる。この様に、本モデルにより美術史における伝記や仮説が定量的に検証できるほか、具体的に色彩のどの特徴において影響を受けたかなど、人手では難しい客観的な分析に本モデルを応用することも可能である。より詳しい分析は、今後の研究で取り組む予定である。

5. む す び

本研究では、統計的機械学習と進化モデルの手法を用いて、絵画芸術における色彩スタイルの文化伝達と進化を分析した。

まず、色彩スタイルクラスターのダイナミクスを分析することにより、スタイルクラスターの頻度変化に同期性が見出され、その主要な要因が作者の色彩スタイル分布が持つ偏りと共有性であることを確認した。次に、色彩スタイル分布の伝達と選択の過程を組み込んだ文化進化モデルである、影響者主導型伝達モデルがランダムモデルよりも歴史的データを良く説明できることを示した。本モデルを用いた教師なし学習により、画像データのみから作者の影響度を推定でき、絵画芸術の歴史における重要な人物を自動的に発見することも示した。これらの結果は、絵画文化において、平均的な色の組合せだけでなく、様々な色の組合せの分布（色彩スタイル分布）も作者間で伝達されており、作者の色彩スタイル分布はそれから作者の影響度がある程度推定可能な情報を有する、創作知識の特質を表していることを示している。

本論文で検討したモデルは現実の進化の過程を単純化したモデルであることに注意が必要である。例えば、モデルを拡張して、複数の文化的親や、作者時定数や斜行伝達係数などのパラメーターの時間変化を含めることができる。4.2節で示された、尤度を最大化するパラメーターと美術史文献における著名な作者の推定精度を最大化するパラメーターとの不一致は、このモデルの不完全性を示している可能性がある。一方で、人よりも大量のデータを処理できるこのモデルは、人では見つけることが容易ではない様な客観的に正しい事実を見つけられる可能性も有している。したがって、今後はより精緻なモデルを研究し、これがどのように結果を変えるか（あるいは変えないか）を検証し、さらに、このモデルの能力を定量的に測定するために、合成データなどを用いたベンチマークテストを行う必要がある。

本研究の結果は、生成 AI 技術の拡張に応用できる可能性がある。影響者主導型伝達を伴う進化モデルを用いて、創作データから創作スタイルに関する知識の伝達経路を推定できる。学術文献科学分野では、この様な知識参照データ（引用データ）は、科学的貢献度の定量化²¹⁾や、研究コミュニティの形成過程の理解²²⁾、創造性の性質の解明^{23),24)}など、創造的活動の進化過程を研究するための有益な情報源として活用されている。芸術分野では、自己報告や歴史家による説明はあっても、これらから完全な知識伝達経路の情報が得られることは稀であるため²⁵⁾、データ駆動型の方法で得られる相補的なデータが有用である。この様に新たな創作スタイルが生まれる原理を解明できれば、機械学習手法と統合することで、創造性を持つ生成 AI を実現する目的で利用できる。

最後に、確率的データ生成過程と文化進化過程を統合したモデルに基づく本研究の枠組みは、幅広いデータ領域に適用可能である。本研究で扱った色彩スタイルの他にも、絵画データの重要なスタイル特徴量として、空間構成、ストロークのパターン、描かれた対象などがある。これらの様々な特徴の分析には DNN を適用でき^{8),9)}、データ生成過程のモデルを変更することで、より一般の特徴量に対して同様の分析

が実行できる。本研究では絵画を対象としたが、応用できる他の文化領域として、音楽^{26)~28)}や文学²⁹⁾、料理³⁰⁾などがあり、一般に、複雑な知識の文化伝達が創造的な知能を理解するために重要な領域への適用が考えられる。

謝 辞

有益な議論をして頂いた伊藤貴之氏、持橋大地氏、金子仁美氏、中村元風氏、北村周平氏に感謝する。本研究は JSPS 科研費課題 21K12187, 21K02846, 22H03661, 及び JST 創発的研究支援事業 JPMJPR226X からの支援を受けて行われた。

参 考 文 献

- 1) T. Karras, S. Laine, T. Aila: “A Style-Based Generator Architecture for Generative Adversarial Networks”, Proc. of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 4401–4410 (2019).
- 2) R. Rombach, A. Blattmann, D. Lorenz, P. Esser, B. Ommer: “High-Resolution Image Synthesis with Latent Diffusion Models”, Proc. of IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), pp. 10684–10695 (2022).
- 3) Y. Jiang, S. Chang, Z. Wang: “TransGAN: Two Pure Transformers Can Make One Strong GAN, and That Can Scale Up”, Proc. of Conference on Neural Information Processing Systems (NeurIPS), Vol. 34, pp. 14745–14758 (2021).
- 4) A. Elgammal, B. Liu, M. Elhoseiny, M. Mazzone: “CAN: Creative Adversarial Networks: Generating “Art” by Learning About Styles and Deviating from Style Norms”, Proc. of International Conference on Computational Creativity (ICCC), pp. 96–103 (2017).
- 5) L. L. Cavalli-Sforza, M. W. Feldman: *Cultural Transmission and Evolution*, Princeton University Press (1981).
- 6) M. Perc: “Beauty in Artistic Expressions through The Eyes of Networks and Physics”, Journal of Royal Society Interface, Vol. 17, No. 20190686, pp. 1–13 (2018).
- 7) H. Y. D. Sigaki, M. Perc, H. V. Ribeiro: “History of Art Paintings Through The Lens of Entropy and Complexity”, Proc. of the National Academy of Sciences of the USA, Vol. 115, No. 37, pp. E8585–E8594 (2018).
- 8) A. Elgammal, B. Liu, D. Kim, M. Elhoseiny, M. Mazzone: “The Shape of Art History in The Eyes of The Machine”, Proc. of AAAI Conference on Artificial Intelligence, Vol. 32, pp. 2183–2191 (2018).
- 9) E. Cetinic, T. Lipic, S. Grgic: “Learning The Principles of Art History with Convolutional Neural Networks”, Pattern Recognition Letters, Vol. 129, pp. 56–62 (2020).
- 10) B. Lee, D. Kim, S. Sun, H. Jeong, J. Park: “Heterogeneity in Chromatic Distance in Images and Characterization of Massive Painting Data Set”, PLOS One, Vol. 13(9), No. e0204430, pp. 1–16 (2018).
- 11) P. H. R. Zivic, F. Shifres, G. A. Cecchi: “Perceptual Basis of Evolving Western Musical Styles”, Proc. of the National Academy of Sciences of the USA, Vol. 110, No. 24, pp. 10034–10038 (2013).
- 12) M. Mauch, R. M. MacCallum, M. Levy, A. M. Leroi: “The Evolution of Popular Music: USA 1960–2010”, Royal Society Open Science, Vol. 2, No. 150081, pp. 1–10 (2015).
- 13) C. Weiß, M. Mauch, S. Dixon, M. Müller: “Investigating Style Evolution of Western Classical Music: A Computational Approach”, Musicae Scientiae, Vol. 23, No. 4, pp. 486–507 (2019).

- 14) E. Nakamura, K. Kaneko: “Statistical Evolutionary Laws in Music Styles”, *Scientific Reports*, Vol. 9, No. 15993, pp. 1–11 (2019).
- 15) E. Nakamura, Y. Saito: “Evolutionary Analysis and Cultural Transmission Models of Color Style Distributions in Painting Arts”, *Proc. of Asia Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, pp. 493–500 (2023).
- 16) A. P. Dempster, N. M. Laird, D. B. Rubin: “Maximum Likelihood from Incomplete Data via The EM Algorithm”, *Journal of the Royal Statistical Society: Series B (Methodological)*, Vol. 39, No. 1, pp. 1–22 (1977).
- 17) R. Singh, E. Nakamura: “Dynamic Cluster Structure and Predictive Modelling of Music Creation Style Distributions”, *Royal Society Open Science*, Vol. 9, No. 220516, pp. 1–18 (2022).
- 18) J. F. Crow, M. Kimura: *An Introduction to Population Genetics Theory*, Harper and Row Publishers (1970).
- 19) D. Wang, C. Song, A.-L. Barabási: “Quantifying Long-Term Scientific Impact”, *Science*, Vol. 342, No. 6154, pp. 127–132 (2013).
- 20) E. H. Gombrich: *The Story of Art (16th ed.)*, Phaidon Press (1995).
- 21) O. Penner, R. K. Pan, A. M. Petersen, K. Kaski, S. Fortunato: “On The Predictability of Future Impact in Science”, *Scientific Reports*, Vol. 3, No. 1, pp. 1–8 (2013).
- 22) R. Klavans, K. W. Boyack: “Which Type of Citation Analysis Generates The Most Accurate Taxonomy of Scientific and Technical Knowledge?”, *Journal of the Association for Information Science and Technology*, Vol. 68, No. 4, pp. 984–998 (2017).
- 23) V. Larivière, S. Haustein, K. Börner: “Long-Distance Interdisciplinarity Leads to Higher Scientific Impact”, *PLOS One*, Vol. 10(3), No. e0122565, pp. 1–15 (2015).
- 24) L. Wu, D. Wang, J. A. Evans: “Large Teams Develop and Small Teams Disrupt Science and Technology”, *Nature*, Vol. 566, No. 7744, pp. 378–382 (2019).
- 25) D. Park, J. Nam, J. Park: “Novelty and Influence of Creative Works, and Quantifying Patterns of Advances Based on Probabilistic References networks”, *EPJ Data Science*, Vol. 9, No. 2, pp. 1–15 (2020).
- 26) D. Park, A. Bae, M. Schich, J. Park: “Topology and Evolution of The Network of Western Classical Music Composers”, *EPJ Data Science*, Vol. 4, No. 2, pp. 1–15 (2015).
- 27) M. Interiano, K. Kazemi, L. Wang, J. Yang, Z. Yu, N. L. Komarova: “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).
- 28) E. Nakamura: “Computational Analysis of Selection and Mutation Probabilities in The Evolution of Chord Progressions”, *Proc. of International Symposium on Computer Music Multi-disciplinary Research (CMMR)*, pp. 462–473 (2023).
- 29) C. O. Brand, A. Acerbi, A. Mesoudi: “Cultural Evolution of Emotional Expression in 50 Years of Song Lyrics”, *Evolutionary Human Sciences*, Vol. 1, No. e11, pp. 1–14 (2019).
- 30) O. Kinouchi, R. W. Diez-Garcia, A. J. Holanda, P. Zambianchi, A. C. Roque: “The Non-Equilibrium Nature of Culinary Evolution”, *New Journal of Physics*, Vol. 10, No. 073020, pp. 1–8 (2008).



中村 栄太 (正会員)

2012 年 東京大学大学院理学系研究科物理学専攻博士課程修了。国立情報学研究所，明治大学，京都大学などで研究員として勤務した後，現在，京都大学 白眉センター/大学院情報学研究科 特定助教。文化知能情報学，文化進化，機械学習，統計物理に関する研究に従事。



齋藤 康之 (正会員)

2000 年 北陸先端科学技術大学院大学 情報科学研究科 情報処理学専攻 博士課程単位取得退学。木更津工業高等専門学校 情報工学科 助手，講師，助教授を経て現在 准教授。博士（情報科学）。IEEE，情報処理学会など各会員。画像処理，音楽情報科学，Open Air Museum に関する研究に従事。

(2023 年 6 月 27 日 受付)

(2023 年 10 月 10 日 再受付)