

コンテンツの人気度を考慮したN次創作活動のモデル化

佃 洸撰^{1,a)} 濱崎 雅弘^{1,b)} 後藤 真孝^{1,c)}

概要: 本稿では、オリジナルコンテンツから次々と新しい派生コンテンツが制作されるN次創作活動において、派生コンテンツの制作を引き起こした要因を推定するためのモデルを提案する。提案モデルでは、クリエイターが派生コンテンツを制作する際に次の3つの要因が影響すると考える：(1) オリジナルコンテンツの魅力、(2) オリジナルコンテンツの人気、(3) 派生コンテンツの人気。オリジナルコンテンツと派生コンテンツの人気は、コンテンツのランキング情報および、クリエイターがランキングを閲覧する際の振る舞いに基づいて求める。本研究の貢献は次の3点である。(1) N次創作活動のモデル化に取り組んだ初めての研究である。(2) 音楽コンテンツに関する実世界のN次創作活動データを用いて、提案モデルの有用性を定量的に示した。(3) 提案モデルを用いることで、ドメインが持つ特性や、派生コンテンツの制作を引き起こした要因の時間的推移などの分析が可能になることを定性的に示した。

1. はじめに

プロのクリエイターが中心となってコンテンツを制作しweb上で発信していた時代は過ぎ、現在ではアマチュアのクリエイターも容易にコンテンツの制作とweb上での発信ができるようになった。そのようなコンテンツはUGC (User Generated Content) と呼ばれる。一から新しいコンテンツを制作することが難しいクリエイターの間では、既存のオリジナルコンテンツを元にした新しい派生コンテンツの制作が盛んに行われている [1]。たとえば YouTube^{*1} では、既存の楽曲に合わせて歌ったり踊ったりする派生動画が多数投稿されている。3Dプリンタ用の3Dモデルを共有できるwebサービス Thingiverse^{*2} では、あるクリエイターが投稿したオリジナルのモデルを別のクリエイターがダウンロードして加工し、新たなモデルを投稿することが行われている。このような創作活動では、第1世代にあたるオリジナルコンテンツから第2世代のコンテンツが制作され、第2世代のコンテンツに影響されたクリエイターが第3世代のコンテンツを、第N世代のコンテンツに影響されたクリエイターが第N+1世代のコンテンツを制作することが起こりうる。このような派生コンテンツの創作活動は「N次創作活動 [2]」と呼ばれる。

N次創作活動は盛んであるが、それぞれの派生コンテンツはなぜ制作されたのだろうか。制作を引き起こした要因がweb上で明示的に記述されることは少ないため、要因の特定は難しい。本研究では、クリエイターが派生コンテンツを制作する際には次の3つの要因が影響すると考える：

(1) オリジナルコンテンツの魅力、(2) オリジナルコンテンツの人気、(3) 派生コンテンツの人気。各要因の詳細は3.2節で述べる。この仮定に基づき、派生コンテンツの制作を引き起こした要因を推定するモデルを提案する。3つの各要因に対する重要度はクリエイターによって異なると考えられるため、提案モデルではクリエイターと各要因の関係の強さも考慮する。さらに提案モデルでは、オリジナルコンテンツと派生コンテンツの人気度を考慮するためにコンテンツのランキング情報を利用する。具体的には、webの検索結果の閲覧モデル [3] を参考に、ランキングで上位に出現したコンテンツほど高い確率で多くのクリエイターの目に触れるためN次創作活動において高い影響力を持つという仮説に基づいたモデル化を行う。提案モデルは、確率的EMアルゴリズム [4] を用いることで派生コンテンツの制作を引き起こした要因を推定する。

本研究の主な貢献をあげる。(1) N次創作活動のモデル化に取り組んだ初めての研究である。提案モデルでは、オリジナルコンテンツの魅力、オリジナルコンテンツの人気、派生コンテンツの人気、の3つの要因を同時に考慮することができる。(2) 音楽コンテンツのN次創作活動データを用いて提案モデルの有用性を定量的に評価し、上記の3つの要因を考慮した場合が最も精度高くモデル化できることを示した。また、コンテンツの人気度に基づくランキングを考慮する際は、ランキング閲覧時のクリエイターの振る舞いを反映したモデルが最も精度が高いことも示した。(3) ドメインの特性、派生コンテンツの制作を引き起こした要因の時間的推移、オリジナルコンテンツを起点とする派生の過程、の観点から定性的な評価を行い、提案モデルがN次創作活動の分析に利用できることを示した。

2. 関連研究

[N次創作活動の分析] Etoら [5] は3Dモデルの制作と

¹ 国立研究開発法人 産業技術総合研究所

a) k.tsukuda@aist.go.jp

b) masahiro.hamasaki@aist.go.jp

c) m.goto@aist.go.jp

*1 <http://www.youtube.com>

*2 <http://www.thingiverse.com>

共有および、既存モデルを用いた派生モデルの制作を可能とする web サイトを公開した。彼らは 10.4%のモデルが他のモデルの派生元になっていること、派生創作活動は最長で第 4 世代まで続いたことを報告している。Cheliotic ら [6] はオンライン音楽コミュニティの ccMixer*³ における音楽コンテンツの N 次創作活動の調査を行った。調査の結果、N 次創作活動によってコミュニティ全体のコンテンツ量が飛躍的に増加すると共に、コンテンツの多様性も高くなることが明らかになった。Hamasaki ら [1] は動画共有サービスのニコニコ動画*⁴ 上での派生創作活動を対象とし、オリジナルコンテンツと派生コンテンツの間の自明な親子関係を扱い、各オリジナルコンテンツの派生コンテンツ数などの統計量を分析した。以上の研究では派生コンテンツの制作が「どのように」行われたかを分析しているのに対して、我々は「なぜ」派生コンテンツが制作されたかに着目し、その要因を推定するためのモデルを提案する。

[社会活動における影響のモデル化] 社会活動でのユーザー間の影響が推定できると、影響力の大きいユーザーの特定 [7] や商品の推薦 [8] において有用であるため、多くの推定手法が提案されてきた。主要なアプローチのひとつは、独立カスケードモデル [9] などの情報拡散モデルを用いることである。このモデルでは離散時間を仮定しているが、Saito ら [10] は連続時間を扱うためにポアソン過程に基づくモデルを提案した。彼らのモデルでは、ユーザー間の影響の有無を表すグラフ情報が必要であるが、Iwata ら [4] はグラフ情報が与えられなくてもユーザー間の影響関係を推定するモデル、Shared Cascade Poisson Process (SCPP) を提案した。Tanaka ら [11] は SCPP を拡張し、商品の購買を引き起こした要因を推定するモデルを提案した。彼らはユーザー間の影響に加えて、ユーザーがメディア広告から受ける影響も考慮し、SCPP の考えが商品の購買行動のモデル化にも有用であることを示した。我々のモデルも SCPP および Tanaka ら [11] のモデルを拡張したものであるが、次の点で既存モデルと異なる：(1) 既存モデルではユーザーによって選択されたアイテム（購入された商品など）の影響は考慮する必要がなかった。しかし、N 次創作活動においては、クリエイターによって制作された派生コンテンツ自体も他のクリエイターの創作活動に影響を与える。そのため我々はオリジナルコンテンツと派生コンテンツの両方の影響を扱えるように SCPP を拡張する。(2) 既存モデルではアイテムの人気度がユーザーのアイテム選択に与える影響は一定であると仮定していたが、我々はその影響は時間によって変化すると仮定する。我々の提案モデルではコンテンツの人気度ランキングとクリエイターのランキング閲覧行動を考慮することで、オリジナルコンテンツおよび派生コンテンツの時間に応じた人気度を扱う。

*³ <http://ccmixter.org>

*⁴ <http://www.nicovideo.jp>

3. モデル

社会活動をモデル化する際は、アイテムに対するユーザーの好み（本研究ではオリジナルコンテンツの魅力に対応）およびユーザー間の影響を考慮するのが一般的である [4], [11]。しかし、N 次創作活動においては、クリエイター間の影響が派生コンテンツの制作を引き起こす要因になっていることは報告はされておらず [1], [5], [6]、その存在は疑わしい。その代わりに、「rich-get-richer」に基づく現象が存在するであろうことがこれまでの報告から考えられる [1]。そこで我々は、オリジナルコンテンツおよび派生コンテンツの人気度が N 次創作活動において重要な役割を果たすと仮定する。本章では、4 つの要因（オリジナルコンテンツの魅力、ユーザー間の影響、オリジナルコンテンツの人気、派生コンテンツの人気）を含めたモデルについて述べるが、我々が提案するのはそこからユーザー間の影響を除いた 3 つの要因を含めたモデルである。

3.1 記号の定義

「椅子の 3D モデル」や「既存楽曲を歌った動画」などのドメインおよびデータの観測期間 T が与えられたとき、 \mathcal{I} をある web サービスに時刻 0 から T の間に投稿された対象ドメイン内のオリジナルコンテンツの集合とする。 (t_{ij}^p, u_{ij}^p) をオリジナルコンテンツ $i \in \mathcal{I}$ の j 番目に投稿された派生コンテンツとする。具体的には、クリエイターが $u_{ij}^p \in \mathcal{U}$ が時刻 t_{ij}^p に i の派生コンテンツを投稿したことを表す。 \mathcal{U} は全クリエイター集合である。一般性を失うことなく、派生コンテンツの投稿イベントは投稿時刻に関して昇順に並べられているとする ($j < j'$ に対して $t_{ij}^p \leq t_{ij'}^p$)。 J_i を観測期間中に投稿された i の全派生コンテンツ数とすると、 i の派生コンテンツの投稿イベント集合は $\mathcal{D}_i = \{(t_{ij}^p, u_{ij}^p)\}_{j=1}^{J_i}$ で表される。従って、全てのオリジナルコンテンツの派生コンテンツの投稿イベント集合は $\mathcal{D} = \{\mathcal{D}_i\}_{i \in \mathcal{I}}$ と表される。

クリエイターは web サービス上でオリジナルコンテンツの人気度に基づくランキングを閲覧できるとする。 (t_{ik}^o, r_{ik}^o) を $i \in \mathcal{I}$ の k 番目のランキング入りイベントとし、 i が時刻 t_{ik}^o に r_{ik}^o 位にランキング入りしたことを表す。一般性を失うことなく、ランキング入りイベントはランキング入りした時刻に関して昇順に並べられているとする。 K_i^o を i が観測期間においてランキング入りした回数とすると、 i のランキング入りイベントの集合は $\mathcal{O}_i = \{(t_{ik}^o, r_{ik}^o)\}_{k=1}^{K_i^o}$ と表され、全オリジナルコンテンツのランキング入りイベント集合は $\mathcal{O} = \{\mathcal{O}_i\}_{i \in \mathcal{I}}$ と表される。

クリエイターは派生コンテンツの人気度に基づくランキングも閲覧できるとする。オリジナルコンテンツの場合と同様、 (t_{ik}^c, r_{ik}^c) を i の派生コンテンツの k 番目のランキング入りイベントとする。 K_i^c を i の派生コンテンツが観測期間においてランキング入りした回数とすると、 i の派生コンテン




図 1 クリエータ u が時刻 t にオリジナルコンテンツ i の派生コンテンツを投稿するレート。

ツのランキング入りイベントの集合は $C_i = \{(t_{ik}^c, r_{ik}^c)\}_{k=1}^{K_i^c}$, 全オリジナルコンテンツの全派生コンテンツのランキング入りイベント集合は $C = \{C_i\}_{i \in \mathcal{I}}$ と表される。

3.2 要因

3.2.1 オリジナルコンテンツの魅力

オリジナルコンテンツ i の人気が低い場合でも、クリエイター u が i を魅力的だと感じれば、 u は i の派生コンテンツを制作するかもしれない。 i の魅力は i の様々な特徴量から引き起こされる。たとえば楽曲の場合、メロディや歌詞などの特徴量が考えられる。オリジナルコンテンツの魅力から受ける影響の大きさはクリエイターによって異なり、またその影響に基づいて派生コンテンツを投稿するレートは時刻 0 から T の間で一定であると仮定する (図 1 (a))。ここで、時刻 t におけるレートとは、クリエイターが時刻 t に i の派生コンテンツを投稿する確率を表す。この仮定に基づき、 i の魅力が要因となってクリエイター u が i の派生コンテンツを投稿するレートを次式で求める。

$$f_i(u) = \alpha_i \theta_{0u}.$$

$\alpha_i \geq 0$ はオリジナルコンテンツ i の魅力を表す。 $\theta_{0u} \geq 0$ は u がオリジナルコンテンツの魅力に影響を受ける度合いであり、 $\sum_{u \in \mathcal{U}} \theta_{0u} = 1$ を満たす。図 1 (a) では、青いバーの高さが $\alpha_i \theta_{0u}$ に相当する。

3.2.2 クリエータの影響

クリエイター u' が i の派生コンテンツを投稿すると、クリエイター u は u' から影響を受けて i の派生コンテンツを制作するかもしれない。このとき、たとえば u が u' のファンであれば、 u' は u に対して大きな影響力を持つように、 u' が与える影響の大きさはクリエイターによって異なると仮定する。また、ユーザ間の情報拡散過程のモデル化に倣い [12]、クリエイターの影響力は時間の経過と共に減衰すると仮定する。これらの仮定に基づき、時刻 t' に i の派生コンテンツを投稿した u' の影響で、 u が時刻 t に i の派生コンテンツを投稿するレートを次式で求める。

$$g_{(i,t',u')}(t,u) = \begin{cases} \alpha_{u'} \theta_{u'u} e^{-\gamma_p(t-t')} & \text{if } t' < t \\ 0 & \text{otherwise.} \end{cases}$$

$\alpha_{u'} \geq 0$ は u' の影響力を、 $\theta_{u'u} \geq 0$ は u が u' から影響を受ける度合いを表し、 $\sum_{u \in \mathcal{U} \setminus u'} \theta_{u'u} = 1$ を満たす。 $\mathcal{U} \setminus u'$ は \mathcal{U} から u' を除いた集合を表す。つまり、 $\alpha_{u'} \theta_{u'u}$ は u' から

u への影響力となる。 $e^{-\gamma_p(t-t')}$ は、パラメータ $\gamma_p \geq 0$ のもとで時間の経過と共に影響力が減衰することを表す。

図 1 (b) では、2人のクリエイターが i の派生コンテンツを投稿している。赤色で表された1人目のクリエイターを u' とすると、 u' の影響力は u' が派生コンテンツを投稿した時刻 t_{i1}^p では $\alpha_{u'} \theta_{u'u}$ (図中の h_1 に相当) であり、時間の経過と共に影響力は減少していく。

3.2.3 オリジナルコンテンツの人気

オリジナルコンテンツ i が消費者の間で人気であれば、 i を見たクリエイター u が i の派生コンテンツを制作するかもしれない。3.1節で述べたように、本研究ではクリエイターがオリジナルコンテンツの人気度ランキングを閲覧できると仮定する。2つのコンテンツがランキング入りしているとき、ランキング上位のコンテンツの方が高い影響力を持つという仮説を立てる。また、3.2.2項と同様に、オリジナルコンテンツの人気が与える影響はクリエイターによって異なり、影響力は時間の経過と共に減衰すると仮定する。この仮定に基づき、 i の人気の影響で u が時刻 t に i の派生コンテンツを投稿するレートを次式で求める。

$$h_{o(i,t',r')}(t,u) = \begin{cases} rb(r') \omega_i \theta_{-1u} e^{-\gamma_o(t-t')} & \text{if } t' < t \\ 0 & \text{otherwise.} \end{cases}$$

r' は i の時刻 t' におけるランキング内での順位を、関数 rb は順位によるバイアスを表す。ユーザの web 検索結果の閲覧時の振る舞いを分析した研究では、web ページの順位が低くなると共に、閲覧される確率は急激に下がることが報告されている [3]。この閲覧モデルに基づき、本研究では順位によるバイアスを $rb(r') = \frac{1}{r'}$ により求める。 $\omega_i \geq 0$ は i の人気による影響力を、 $\theta_{-1u} \geq 0$ は u がオリジナルコンテンツの人気から影響を受ける度合いを表し、 $\sum_{u \in \mathcal{U}} \theta_{-1u} = 1$ を満たす。 $e^{-\gamma_o(t-t')}$ は、パラメータ $\gamma_o \geq 0$ のもとで時間の経過と共に影響力が減衰することを表す。

図 1 (c) では、 i はランキングに4回出現している。最初のランキング入り時の順位を r' 、時刻を t_{i1}^o とすると、 t_{i1}^o における影響力は $rb(r') \omega_i \theta_{-1u}$ (図中の h_2 に相当) であり、時間の経過と共に影響力は減少していく。

3.2.4 派生コンテンツの人気

クリエイター u' が制作した i の派生コンテンツが消費者の間で人気であれば、その派生コンテンツを見たクリエイター u は、たとえ u' のファンではないとしても、 i の派生コン

テンツを制作するかもしれない。3.2.3 項で述べた仮説および仮定と同様に、 i の派生コンテンツが時刻 t' に r' 位にランキング入りした場合、その影響で u が時刻 t に i の派生コンテンツを投稿するレートを次式で求める。

$$h_{d(i,t',r')}(t,u) = \begin{cases} rb(r')\sigma_i\theta_{-2u}e^{-\gamma_d(t-t')} & \text{if } t' < t \\ 0 & \text{otherwise.} \end{cases}$$

$\sigma_i \geq 0$ は i の派生コンテンツの人気による影響力を、 $\theta_{-2u} \geq 0$ は u が派生コンテンツの人気から影響を受ける度合いを表し、 $\sum_{u \in \mathcal{U}} \theta_{-2u} = 1$ を満たす。 $e^{-\gamma_d(t-t')}$ は、 $\gamma_d \geq 0$ のもとで時間の経過による影響力の減衰を表す。

図 1 (d) および (e) では、 i の 1 番目の派生コンテンツと 2 番目の派生コンテンツの影響力をそれぞれ表している。図 1 (d) の最初のランキング入りの順位を r' とすると、最初にランキング入りした時刻 t_{i1}^c における影響力は $rb(r')\sigma_i\theta_{-2u}$ (図中の h_3 に相当) であり、時間の経過と共に影響力は減少していく。

3.3 派生コンテンツの投稿レート

3.2.1 項から 3.2.4 項で述べた要因に基づき、クリエイター u が時刻 t にオリジナルコンテンツ i の派生コンテンツを投稿するレートを次式で表す。

$$\lambda_i(t,u) = f_i(u) + \sum_{(t',u') \in \mathcal{D}_{it \setminus u}} g_{(i,t',u')}(t,u) + \sum_{(t',r') \in \mathcal{O}_{it}} h_{o(i,t',r')}(t,u) + \sum_{(t',r') \in \mathcal{C}_{it}} h_{d(i,t',r')}(t,u)$$

ここで、 $\mathcal{D}_{it \setminus u} = \{(t',u') | (t',u') \in \mathcal{D}_i \text{ and } t' < t \wedge u' \neq u\}$ 、 $\mathcal{O}_{it} = \{(t',r') | (t',r') \in \mathcal{O}_i \text{ and } t' < t\}$ 、 $\mathcal{C}_{it} = \{(t',r') | (t',r') \in \mathcal{C}_i \text{ and } t' < t\}$ である。 $\lambda_i(t,u)$ は図 1 (f) 中の h_4 に相当する。

観測データ \mathcal{D} 、 \mathcal{O} 、 \mathcal{C} が与えられたとき、 \mathcal{D} の尤度関数は次式で表される。

$$P(\mathcal{D}|\mathcal{O},\mathcal{C},\alpha,\omega,\sigma,\Theta,\gamma) = \prod_{i \in \mathcal{I}} \exp\left(-\int_0^T \sum_{u \in \mathcal{U}} \lambda_i(t,u) dt\right) \prod_{j=1}^{J_i} \lambda_i(t_{ij}^p, t_{ij}^p).$$

パラメータは $\alpha = \{\alpha_i\}_{i \in \mathcal{I} \cup \mathcal{U}}$ 、 $\omega = \{\omega_i\}_{i \in \mathcal{I}}$ 、 $\sigma = \{\sigma_i\}_{i \in \mathcal{I}}$ 、 $\Theta = \{\theta_u\}_{u \in \mathcal{U}_+}$ 、 $\theta_u = \{\theta_{uu'}\}_{u' \in \mathcal{U} \setminus u}$ 、 $\gamma = \{\gamma_p, \gamma_o, \gamma_d\}$ である。 \mathcal{U}_+ は $\mathcal{U} \cup \{0, -1, -2\}$ を表し、 $0, -1, -2$ はそれぞれ、オリジナルコンテンツの魅力、オリジナルコンテンツの人気、派生コンテンツの人気、に相当する仮想クリエイターを表す。Iwata ら [4] に倣い、ベイズ推定に基づいて各パラメータの事前分布を仮定し、確率的 EM アルゴリズムを用いることでパラメータおよび事前分布のハイパーパラメータを推定する。紙面の都合上、詳細は割愛する。

4. 定量的評価

本章では、実験を通して次の疑問に答える。オリジナル

表 1 データセットの統計量

| | $ \mathcal{I} $ | $ \mathcal{O} $ | $ \mathcal{D} $ | $ \mathcal{C} $ | $ \mathcal{U} $ |
|--------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 歌ってみた | 4,035 | 64,973 | 199,320 | 67,627 | 18,715 |
| 踊ってみた | 396 | 30,925 | 9,420 | 22,954 | 1,153 |
| 演奏してみた | 583 | 38,726 | 5,526 | 20,492 | 692 |

コンテンツの魅力、オリジナルコンテンツの人気、派生コンテンツの人気、の 3 つの要因を考慮することは N 次創作活動をモデル化する際に有効か (4.2 節)。 N 次創作活動をモデル化する際に、コンテンツの人気度ランキングの順位に対してどのようなバイアスをかけるのが有効か (4.3 節)。

4.1 データセット

本実験では、動画共有サービス「ニコニコ動画」の N 次創作活動データを使用した。ニコニコ動画では、特に音楽コンテンツの N 次創作活動が盛んであり、2016 年 7 月の時点で 14 万件以上のオリジナルコンテンツと 60 万件以上の派生コンテンツが投稿されている。大部分のオリジナルコンテンツは VOCALOID と呼ばれる歌声合成技術を用いて制作された楽曲である。派生コンテンツに関しては、オリジナル曲を歌う「歌ってみた」、オリジナル曲に合わせて踊る「踊ってみた」、オリジナル曲を演奏する「演奏してみた」の 3 つのドメインを対象として実験を行った。本実験では 2010 年 1 月 1 日から 2013 年 3 月 31 日の間に投稿されたオリジナルコンテンツおよび、2010 年 1 月 1 日から 2013 年 6 月 30 日の間に投稿された派生コンテンツを対象とした。2010 年 1 月 1 日から 2013 年 3 月 31 日の間のデータを学習データ、2013 年 4 月 1 日から 2013 年 6 月 30 日の間のデータをテストデータとした。いずれのドメインでも、学習期間において派生コンテンツが 2 件未満のオリジナルコンテンツおよび、派生コンテンツの投稿件数が 3 件未満のクリエイターはデータセットから除いた。

ニコニコ動画では、オリジナルコンテンツおよび上記の 3 ドメインの派生コンテンツそれぞれについて、日単位で人気コンテンツの上位 100 件を見ることができる。1 日のランキングは、前日の閲覧数やコメント数などのいくつかの指標を元に作成される。我々は 2010 年 1 月 1 日から 2013 年 6 月 30 日の間の、オリジナルコンテンツおよび 3 ドメインの派生コンテンツの上位 100 件のランキングデータを収集した。ランキングデータが日単位であるため、派生コンテンツの投稿時刻も日単位で扱った。

表 1 に本実験で使用したデータセットの統計量を示す。

4.2 要因の組合せが与える影響

[比較モデル] Oatt, Uinf, Opop, Dpop をそれぞれオリジナルコンテンツの魅力、クリエイターの影響、オリジナルコンテンツの人気、派生コンテンツの人気とする。3 章で述べたように、我々は Oatt, Opop, Dpop を含むモデルが最も効果的であるという仮説を立てた。この仮説を検証するために、次の 6 種類のモデルを比較した：(1) Oatt, (2) Oatt+Uinf, (3) Oatt+Uinf+Opop+Dpop, (4)




図 2 モデルごとの負の対数尤度. 縦軸: 負の対数尤度. 横軸: テスト期間.

Oatt+Opop, (5) Oatt+Dpop, (6) Oatt+Opop+Dpop. たとえば Oatt+Uinf は, Oatt と Uinf を含むモデルであることを表す. 6 種類のモデルの中で, (2) は CCPP [4] に対応し, (6) が我々の提案モデルに対応する.

[評価指標] 提案モデルの妥当性を評価するために, モデルの予測精度をテストデータに対する負の対数尤度によって評価する. テスト期間を T から T' としたとき, テスト期間中の派生コンテンツの投稿イベント (t, u) の負の対数尤度は次式で表される.

$$L = - \sum_{i \in \mathcal{I}} \left(- \int_T^{T'} \sum_{u \in \mathcal{U}} \lambda_i(t, u) dt \right) \sum_{(t, u) \in \mathcal{D}_i^{\text{test}}} \log \lambda_i(t, u).$$

$\mathcal{D}_i^{\text{test}}$ は i のテストデータであり, L の値が小さいほど予測精度が高いことを表す. テスト期間の長さの影響も調べるため, テスト期間を 1 ヶ月 (2013 年 4 月 1 日から 2013 年 4 月 30 日) から 3 ヶ月 (2013 年 4 月 1 日から 2013 年 6 月 30 日) まで 1 ヶ月単位で増加させた.

[結果] 結果を図 2 に示す. 各テスト期間で最も予測精度の高かったモデルを「*」で示す. 「歌ってみた」および「踊ってみた」では, 提案モデルの Oatt+Opop+Dpop が全てのテスト期間で最も予測精度が高かった. 「演奏してみた」では, 提案モデルが最も高い精度にはならなかったが, 全てのドメインの全てのテスト期間で安定して高い精度を記録していた. 「演奏してみた」で最も高い精度を記録したモデルは, 「歌ってみた」や「踊ってみた」における予測精度が低いこともあり, 安定性に欠ける結果であった. これらの結果から, 比較した 6 種類のモデルの中では, Oatt, Opop, Dpop を考慮した提案モデルが N 次創作活動をモデル化する上で最も有用であると言える.

4.3 順位によるバイアスのかけかたの比較

[セッティング] 3.2.3 項で述べたように, 提案モデルでは人気度ランキング中の順位の逆数を用いて順位によるバイアスをかける (以降, この手法を Reciprocal と呼ぶ). 提案手法の有用性を検証するために, 次の 2 つの手法との比較を行う. 1 つ目の手法 (Linear 手法) は, 順位によるバイアスを線形に変化させる: $rb(r_{ik}^o) = \frac{101-r_{ik}^o}{100} \cdot rb(r_{ik}^c)$ も同様に計算する. この手法では, コンテンツの順位が下がっても, その影響力は Reciprocal 手法ほど急激に減らなないと仮定している. 2 つ目の手法 (Uniform 手法) は, 順位によるバイアスを考慮しない. つまり, 順位によらず $rb(r_{ik}^o) = rb(r_{ik}^c) = 1$ とし, ランキング内のコンテンツは




図 3 ランキング中の順位によるバイアスのかけかたの手法ごとの負の対数尤度.

表 2 推定された要因の比率 (%)

| 要因 | 歌ってみた | 踊ってみた | 演奏してみた |
|------|-------|-------|--------|
| Oatt | 14.6 | 17.3 | 42.5 |
| Opop | 40.0 | 21.7 | 40.0 |
| Dpop | 45.4 | 61.0 | 17.5 |

すべて同じ影響力を持つと仮定している. 各手法の評価には, 4.2 節と同様に負の対数尤度を用いた.

[結果] 図 3 に結果を示す. Reciprocal 手法が全てのドメインの全てのテスト期間において他の 2 手法の予測精度を上回っていることから, クリエータのランキング閲覧時の振り舞いを考慮した Reciprocal 手法が N 次創作活動をモデル化する上で最も有用であると言える.

5. 定性的評価

提案モデルを用いて, 学習期間における各派生コンテンツの投稿が 3 つの各要因から影響を受けた度合いを推定することで, 定性的な評価を行った.

5.1 ドメインが持つ特性

テスト期間中の 3 つの各要因の影響の大きさの比率を表 2 にドメインごとに示す. 3 つの要因の比率はドメインによって大きく異なっていた. 「歌ってみた」では, Opop および Dpop の比率が高く, Oatt の比率が低い. この結果から, 「歌ってみた」のクリエイータは流行に敏感で, コンテンツの人気を重視して派生コンテンツを制作していることが予想される. 「踊ってみた」カテゴリでは Dpop の比率が高い. 「踊ってみた」では, 全てのクリエイータが独自の振付を考えられるわけではない. そのため, あるクリエイータが振付を考えて踊った派生コンテンツを投稿し, その後, 他のクリエイータがその振付を真似て派生コンテンツを投稿することがよく行われている. 表の結果は, 提案モデルによってこのような特性を捉えられていることを示している. 「演奏してみた」では, Oatt の比率が高いため, クリエータは流行にはとらわれずに, 自分の好きな楽曲を演奏して派生コンテンツを制作していることが予想される.

5.2 要因の時間的推移

図 4 に, ドメインごとにあるオリジナルコンテンツの派生コンテンツの制作を引き起こした要因の時間的推移の推定結果を示す. 横軸は 1 ヶ月単位で表記されており, 最初の月は派生コンテンツが初めて投稿された月である. 縦軸は各月の派生コンテンツの総投稿数を表す. 棒グラフの青, オレンジ, 赤はそれぞれ Oatt, Opop, Dpop によって




図 4 あるオリジナルコンテンツに着目したときの、3つの各要因によって引き起こされたと推定された派生コンテンツの投稿数。縦軸は各月の派生コンテンツの総投稿数を表す。




図 5 「踊ってみた」カテゴリでの派生の過程。

引き起こされたと推定された派生コンテンツの投稿数を表す。ここでも、ドメインごとの特徴が現れていることがわかる。「歌ってみた」では、初期の段階では Oatt と Opop の影響が大きく、その後 Dpop の影響が大きくなることから、初期に投稿された派生コンテンツが人気になり、その後 Dpop を重視するクリエイターもこのオリジナルコンテンツの派生コンテンツを投稿したことが予想される。「踊ってみた」では、初期の段階では独自に振付を考えられる限られたクリエイターが派生コンテンツを投稿し(最初の2ヶ月の青部分に相当)、その後、それらの派生コンテンツに影響を受けた多くのクリエイターが新しい派生コンテンツを投稿していることが読み取れる。「演奏してみた」では、期間の前半では Opop や Dpop を重視するクリエイターによる派生コンテンツの投稿が盛んであるが、期間後半にコンテンツの人気も衰えても、Oatt を重視するクリエイターによって派生コンテンツが投稿され続けていることがわかる。

5.3 オリジナルコンテンツを起点とする派生の過程

図 5 に「踊ってみた」のあるオリジナルコンテンツの派生コンテンツの派生過程を示す。図中で 0 はオリジナルコンテンツを、 $j \geq 1$ は j 番目に投稿された派生コンテンツを表す。数字間の枝は下の数字のコンテンツが上の数字のコンテンツの影響を受けて制作されたことを表す。この例では、9番目と11番目の派生コンテンツが次の世代の多くの派生コンテンツの制作を引き起こしており、N次創作活動において重要な役割を果たしていることがわかる。また、この例では第10世代まで派生コンテンツ(30番目、32番目、33番目)が存在することがわかる。

6. まとめ

本稿では派生コンテンツの制作を引き起こした要因を推定するためのモデルを提案した。今後の課題として、Thingiverse などの他ドメインの N 次創作活動データに提案モデルを適用して有用性を検証すること、5章で示したような分析結果を web 上で閲覧するためのインタフェースを提案することなどがあげられる。

謝辞

本研究の一部は、文部科学省科学研究費補助金研究活動スタート支援(課題番号 15H06887)および科学技術振興機構 OngaCREST プロジェクトの支援を受けた。

参考文献

- [1] M. Hamasaki *et al.*: “Network analysis of massively collaborative creation of multimedia contents: Case study of hatsune miku videos on nico nico douga”, UXTV, pp. 165–168 (2008).
- [2] M. Goto: “Grand challenges in music information research”, Dagstuhl Follow-Ups: Multimodal Music Processing, **3**, pp. 217–225 (2012).
- [3] T. Joachims *et al.*: “Accurately interpreting click-through data as implicit feedback”, SIGIR, pp. 154–161 (2005).
- [4] T. Iwata *et al.*: “Discovering latent influence in online social activities via shared cascade poisson processes”, KDD, pp. 266–274 (2013).
- [5] K. Eto *et al.*: “Modulobe: A creation and sharing platform for articulated models with complex motion”, ACE, pp. 305–308 (2008).
- [6] G. Cheliotis and J. Yew: “An analysis of the social structure of remix culture”, C&T, pp. 165–174 (2009).
- [7] X. Song *et al.*: “Information flow modeling based on diffusion rate for prediction and ranking”, WWW, pp. 191–200 (2007).
- [8] X. Song *et al.*: “Personalized recommendation driven by information flow”, SIGIR, pp. 509–516 (2006).
- [9] J. Yang and J. Leskovec: “Modeling information diffusion in implicit networks”, ICDM, pp. 599–608 (2010).
- [10] K. Saito *et al.*: “Learning continuous-time information diffusion model for social behavioral data analysis”, ACML, pp. 322–337 (2009).
- [11] Y. Tanaka *et al.*: “Inferring latent triggers of purchases with consideration of social effects and media advertisements”, WSDM, pp. 543–552 (2016).
- [12] S. Myers and J. Leskovec: “On the convexity of latent social network inference”, Advances in Neural Information Processing Systems 23, pp. 1741–1749 (2010).