

暗意実現モデルに基づき作曲家識別を行う HMM について

能登 楓^{1,a)} 竹川 佳成^{1,b)} 平田 圭二^{1,c)}

概要: 本研究では、音楽から受ける「作曲家らしさ」をメロディから識別する手法を提案する。一般に、作曲者は多種多様な曲を創作しているため、共通する作曲家らしさは主観的な印象となってしまう。本稿では、暗意実現モデルに基づいた楽曲分析より、期待感の実現、逸脱を隠れ状態として想定とした隠れマルコフモデル (Hidden Markov Model; HMM) を作成し、その有用性について議論する。ここで、暗意実現モデルとは、旋律に対する音楽理論であり、旋律の期待感の実現、逸脱によって楽曲を分析する。我々は、作曲家らしさをモデル化するための方針として、メロディが時系列情報であることに着目した。提案モデルの有用性を検証するため、評価実験を行なった。評価実験では未知のメロディに対して、最も高い生成確率を与える作曲家モデルを未知のメロディが属する作曲家モデルと、未知メロディの識別を行なった結果、識別率の平均は約 64%であった。

About HMM which Performs Composer Identification Based on Implication-Realization Model

KAEDA NOTO^{1,a)} YOSHINARI TAKEGAWA^{1,b)} KEIJI HIRATA^{1,c)}

1. はじめに

聴取者は「バッハのような音楽」や「ショパンのような音楽」というように自身の好みの楽曲を作曲家らしさを用いて楽曲を表現することがある。また、このように楽曲から受ける印象として、作曲家らしさのみならずジプシー風やカントリー風、アラビア風といった地域や文化らしさを指すこともある。

実際に後者の地域や文化らしさを表現するような楽曲を多くの作曲家が作曲している。たとえば、ドイツの作曲家である J. Brahms の『ハンガリー舞曲』はハンガリーのジプシー音楽に基づいて編曲されたものである。また、イタリアの作曲家である Vittorio Monti の『チャールダーシュ』は表題がそのまま「酒場風」というハンガリーの音楽ジャンルを表している。音楽学において民族音楽の音楽構造に関する分析は行われており、民族音楽に特有に現れる音程

関係は音階としてまとめられている [5]。そのため、ジプシー風やハンガリー風の曲を作るためには、ハンガリー・スケール、ジプシー・スケールといった音階を用いれば良い。このように、地域や文化らしさを表現するような、いわゆる民族音楽というジャンルにおいては「地域・文化らしい音楽」を作曲することができるよう体系化されている。

一方、楽曲における作曲家らしさというものは体系化されていない。一般に人は楽曲の断片を聴取しただけで、「作曲家らしさ」を感じることができるとは、その理由を客観的に説明することは難しい。それは、作曲家は多種多様な曲を作曲しているため、共通する作曲家らしさは主観的な印象となってしまうからである。このように、作曲家らしさを定量的に説明することは困難であり、また、計算機による作曲家推定も困難である。

楽曲間の近さは、観点によって適切な近さを定義する必要がある。聴取した印象が類似するという観点に基づいて楽曲間類似度を算出した松原らの研究では、人が音楽を聴き二つの旋律が似ているかどうかを感じることができる構造的な側面を暗黙うちに比べているという仮定のもと音楽理論の一つであり、楽曲の構造を分析する GTTM という

¹ 公立はこだて未来大学
Future University Hakodate

a) b1014018@fun.ac.jp

b) yoshi@fun.ac.jp

c) hirata@fun.ac.jp

手法を用いて類似度を算出している [9].

作曲家らしさを推定するという問題は、同一作曲者の作成した楽曲が近くなるような距離を定義することである。ある作品をその作曲家の作品らしくさせている特徴や構造をイデオストラクチャと呼ぶ [11]。作曲家は自分自身で自身のイデオストラクチャを発見し、取捨選択することによって自身の作品らしい楽曲を創作する。イデオストラクチャを構成するものは、メロディ遷移、和音、調性、リズムといった様々な要素の組み合わせである。本研究では中でもメロディ遷移に着目し、メロディに関する認知的音楽理論の一つである暗意実現モデルをもとに分析を行った。

本研究では、旋律を時系列情報であるとみなし、作曲家らしさを表現する隠れマルコフモデル (HMM) を作成する。HMM を作成するにあたって、暗意実現モデルに基づき HMM のパラメータを検討した。また、作成した HMM の妥当性を検討した。

2. 関連研究

本章では、音楽学における曲種や時代の個性的な特徴を見出す手法 (2.1 節)、様式分析手法に基づき、計算器上で作曲家らしさ推定を行った研究 (2.2 節)、HMM を用いて作曲家識別を行った研究 (2.3 節)、暗意実現モデルに基づき類似度を計算した研究 (2.4 節)、同一作曲家の複数楽曲において出現する動機に関する研究 (2.5 節) について述べる。

2.1 音楽学における楽曲分析手法

音楽学の分野では、作曲家の音楽的特徴の発見や、印象主義などといった音楽様式を客観的に理解することを目的としている様式分析というものがある。中でも、ラルーらの総合的様式分析という方法では、Sound, Harmony, Melody, Rythm という観点から、複数の楽曲に共通する音楽的特徴について分析を行う。ラルーらは総合適用式分析において、ラーズ、ミドル、スモールの3つのディメンションと呼ばれる分析幅を定義しており、それぞれに異なる分析を行っている [6](表 1)。

表 1 ディメンションの分類

ラーズ・ディメンション (Large Dimentions)	作品群 曲 楽章
ミドル・ディメンション (Middle Dimentions)	パート (部) セクション (部分) フレーズ・グループ (楽節群)
スモール・ディメンション (Small Dimentions)	フレーズ (楽節) サブフレーズ (小楽節) モチーフ (動機)

Meyer は楽曲は作品の特徴、作曲家の特徴、時代や文化の類似した作曲家集合の特徴の3階層から構成される作曲

規則に従って創作されていると述べている [8] この3つのディメンションを Meyer が述べた3階層に対応させると、ラーズ・ディメンションは時代や文化の類似した作曲家集合の特徴、ミドル・ディメンションは作曲家の特徴、スモール・ディメンションは作品の特徴から構成される作曲戦略・規則に従って創作されていると考えることができる。

2.2 譜面から得られる情報を用いた作曲家識別

長谷川らは音楽から受ける「作曲家らしさ」の印象を説明し、定量的に測定できる工学的手法の発見を目指した [4]。音楽学における様式分析手法の1つであるラルーらの総合的様式分析において論じられている様々な定性的特徴をもとに、12つの特徴量を定義した。定義した特徴量は大きく分けて、音数に関するもの、和音に関するもの、メロディに関するもの、リズムに関するものであった。実験では、26作曲家、1966曲のMIDIデータを用いた。選曲に際して様々な文化圏の作曲家の作品、1作曲家あたり20曲以上、様々な種類の楽曲(管弦楽曲、協奏曲、室内楽、器楽曲、声楽曲)であることに留意した。正準判別分析によって未知楽曲の順序つき作曲家識別を行なった結果、正解率は56.1%、2位含有率は73.9%、3位含有率は81.6%であった。また、判別分析結果の階層クラスタ分析により、時代・文化が類似しており、実際に類似した印象を受けると考えられる作曲家は特徴量の重心が近接して配置されていることが示されている。このことより、様式分析手法は作曲家識別に対して有効である。

2.3 HMM を用いた作曲家識別

メロディから作曲家らしさを識別する研究として Pollastri らの研究がある [10]。音楽的表情づけがされていないメロディのMIDI音源に対する作曲家識別実験を行った。Pollastri らは、作曲家のメロディ遷移には特徴があると仮定し、識別を行うためのモデルとしてプロファイル HMM を用いた。プロファイル HMM は機能的あるいは立体構造的に何らかの関連があると思われる多数の配列に対し、特徴を発見することのできるモデルであり、進化的情報の抽出、未知のタンパク質二次構造や立体構造の予測、機能予測などといったパターンを推論する問題において使われる HMM である。作成したプロファイル HMM の観測記号として、音程と音長比によって分類された28つの記号を用いた。実験として、W. A. Mozart, L. v. Beethoven, A. L. Dvorak, I. F. Stravinsky, Beatles に対応したプロファイル HMM を作成し、各モデルは各作曲家楽曲を101曲ずつ学習している。未知のメロディに対して、最も高い生成確率を与える作曲家モデルを未知のメロディが属する作曲家モデルとした。音楽教育を受けた学生の識別率が48%、音楽教育を受けていない学生の識別率が24.6%であるのに対し、Pollastri らの提案した HMM の識別率は42%であった。

2.4 拡張暗意実現モデルに基づく楽曲類似度

矢澤らは、暗意実現モデルに対し、音程の上下方向に関する定義を追加し楽曲間の類似度の算出を行った [12]。拡張された暗意実現モデルでは、もともと 8 つのシンボルで構成されていた暗意実現シンボルを 18 種類に拡張した。類似度の算出方法としては、比較する二つの楽曲を拡張暗意実現モデルに基づくシンボル列で楽曲を表現した記号列 Seq1, Seq2 と定義する。Seq1, Seq2 の類似度を算出する際に、楽曲の N-gram を用いた。N の大きさ, Seq1 と Seq2 の一致した N-gram の個数 M を用いて、類似度を以下の式で定義した。

$$Sim(Seq1, Seq2) = M/A$$

$$A = (|Seq1| + 2(N - 1)) + (|Seq2| + 2(N - 1)) - 2N - M + 2$$

評価実験として、5,000 曲を総当たりで比較を行い、全ての組に対して類似度を算出している。これらの類似度を主観評価実験の結果と比較し、システム出力の妥当性を評価した。主観評価実験の被験者は男女 15 人で全ての楽曲の組に対し、各組はどの程度似ているかという質問に対し、「とても似ている」、「似ている」、「どちらでもない」、「似ていない」、「まったく似ていない」の 5 段階のリッカート尺度による回答項目であった。

2.5 同一作曲家に共通する旋律に関する研究

様式分析では、動機の分析を行うことによって、楽曲が作られた年代の推定や作曲家の推定が可能である。動機は 2 拍から 5 拍程度の長さであり、楽曲中に調やリズムを変更しながら 4-10 回程度出現する。David らは、同一作曲家の複数の楽曲に共通して現れる動機に着目し、作曲家らしさを発見することを目指した。動機の発見には EMI (Experiments in Musical Intelligence) を用いた。共通した動機を発見するために、3 つのルールを設けた。(1) 元の動機の各音に対し、2 度の音程差を許す。(2) 元に動機に対し、逆向きの進行や各音の度数が 2 倍以下となっている進行を許す。(3) 元の動機に対し、音数が多いものを許す。これらのルールを用いて、パターンマッチングを行い、同一作曲家の複数楽曲に現れる動機を発見した。



図 1 暗意実現モデルに基づく期待の実現と否定

パターン名	音程の大きさ	同じ方向	PID	PRD
D	0 0	yes	yes	yes
ID	S S(=)	no	yes	no
P	S S	yes	yes	yes
IP	S L	no	yes	no
VP	S L	yes	no	yes
-	S L	no	no	no
IR	L S	yes	yes	no
R	L S	no	yes	yes
-	L L	yes	no	no
VR	L L	no	no	yes



図 2 暗意実現におけるシンボル

3. 認知的音楽理論による分析手法

3.1 ゲシュタルトに基づく楽曲分析

人が音楽を知覚する際には、音高、音価、発音タイミング、和声に対してゲシュタルトが生じている。ゲシュタルトとは刺激の部分的特徴や要素ではなく、全体的構造や「まとまり」を表す言葉である [3]。人は知覚する際にゲシュタルトによる補完を行なっているため、先取する刺激から不確定な部分を暗意している (図 1)。

Narmour と Meyer はゲシュタルト心理学に基づき旋律をシンボル列へと変換し、分析する方法である暗意実現モデルを提案した [2]。暗意実現モデルでは、近接する 3 音は音程の大きさ、同じ方向、PID、PRD の 4 つのパラメータによって、D(duplication), P(process), ID(intervallic duplication), IP(intervallic process), VP(registral process), R(reversal), IR(intervallic reversal), VR(registral reversal) の 8 つのシンボルに分類される。暗意実現モデルの原理から生み出される全シンボルを図 2 に示す。この表では、全てのパラメータの組み合わせを列挙されている。表中の音程の大きさ S, L はそれぞれ、S は小さい音程 (完全 4 度以下), L は大きい音程 (完全 5 度以上) を示している。暗意実現モデルでは、これら 4 つのパラメータによって 3 音をシンボル化している。シンボル名が“-”となっているものは PID, PRD の原理がどちらも成立していないため、暗意実現シンボルには含まれない

暗意実現モデルにおけるシンボルは、PID, PRD が共に成立するシンボルである P, D, R を暗意が実現するシンボル、それ以外のシンボルを暗意が否定されるシンボルとしている。また、Meyer は暗意が実現する際には情動が生じ、暗意が否定する際には情動が生じないと述べている。

方向原理 (Principle of Registral Direction: PRD)

第 1 音と第 2 音の音程が小さい時、第 3 音で同じ方向の間隔が暗意される。第 1 音と第 2 音の音程が大きいとき、第 3 音では異なる方向の間隔が暗意される。

音程原理 (Principle of Intervallic Difference: PID)

第1音と第2音の音程が小さい時、第3音で同じ方向の間隔が暗意される。第1音と第2音の音程が大ききとき、第3音では異なる方向の間隔が暗意される。

3.2 HMM による作曲家モデルの作成

本研究では、暗意実現モデルに基づいた作曲家のモデルを作成する。旋律が確率的に音が出現するような、時系列情報であるという点に着目し、HMMを用いてモデル化を行う。HMMは観測不可能な隠れ状態を仮定することによって記号の生起確率を確率的に定義することができるモデルである。ある隠れマルコフモデルによって生成された出力の記号列は、隠れ状態の系列に関する何らかの情報を与えるものとなる。つまり、直接関係がないように見える記号に対する解釈を加えることができる。旋律を学習し、次の音を直接推定することは難しいが、隠れ状態を仮定することによって次の音の生起確率を推定することが可能になる。HMMは事前に内部状態数を適切に決定する必要がある。この内部状態は学習後のモデルの出力から解釈することが可能である。

3.1節で紹介した暗意実現モデルにおいて、8つのシンボルは暗意が実現するシンボル、否定されるシンボルに分けられる。そこで、観測記号を暗意実現シンボルとしたHMMを作ることによって、暗意実現モデルに基づくHMMが作成できる。ここで、隠れ状態を暗意の実現、暗意の否定の2状態と仮定することによって、HMMの解釈が容易になる。

本稿では、作曲家ごとに、暗意実現モデルに基づくHMMを作成する。各HMMは作曲家の旋律の遷移を学習したものであり、これらのHMMを用いて作曲家推定を行う。

3.3 観測記号系列の長さ

HMMを学習する際には、パラメータである初期状態確率分布 π 、状態 i から j への状態遷移確率分布 a_{ij} 、状態 j において記号 k を出力する記号出力確率分布 $b_j(k)$ を更新する [7]。

時刻 t のデータに対する確率値を $\gamma_t(i)$ と表すことにする。この時、全ての学習データに対しての状態 i から状態 j へ遷移する回数の期待値 $\sum_t \gamma_t(i, j)$ は各データから得られる期待値の和として求めることができる。状態遷移確率分布 a_{ij} 、記号出力確率分布 $b_j(k)$ の更新式は以下である。

$$\hat{a}_{ij} = \frac{\sum_t \gamma_t(i, j)}{\sum_t \gamma_t(i)} \quad \hat{b}_{jk} = \frac{\sum_{t: o_t=k} \gamma_t(j)}{\sum_t \gamma_t(j)}$$

全学習データに対しての状態 i から状態 j へ遷移する回

数の期待値 $\sum_t \gamma_t(i, j)$ は前向き確率を用いて求める。前向き確率は前向き確率はモデル M が記号系列 $o_1^T = o_1 \cdots o_t$ を生成して、時刻 t で状態 q_i に到達する確率 $\alpha_t(i)$ である。

前向き確率は、次のように再帰的に計算することができる。

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(o_{t+1})$$

式より、時刻 $t+1$ 時点で状態 q_j に到達する確率 $\alpha_t(i)$ は、時刻 t で状態 q_i に到達する確率 $\alpha_t(i)$ に状態遷移確率 a_{ij} をかけることで求めることができる。つまり、値観測記号列の長さが長くなるにつれて、前向き確率は小さくなってしまふ。前向き確率が極端に小さい場合には、パラメータ更新が困難になってしまう。そのため、本研究では (2.1 節) で紹介したミドル・ディメンションであるフレーズグループを1つの観測記号列とした。

4. 実装と実験の実施

4.1 HMM のパラメータに関する検討

HMMの各パラメータの推定には、EMアルゴリズムである Baum-Welch アルゴリズムを用いた。この学習アルゴリズムは、サンプルデータの集合から直接HMMの各パラメータを推定することができる。Baum-Welch アルゴリズムを行うには、学習の前に隠れ状態数、初期状態確率、状態遷移確率、記号出力確率を事前に決定する必要がある。モデルの学習結果はこれらのパラメータに依存し、極大点に収束する。

隠れ状態数は、3.2節で述べたように、2つとしている。これらの状態は暗意が実現する状態と否定される状態を想定している。そのため、暗意が実現する状態が出力する記号は P, D, R, 否定される状態が出力する記号は ID, IP, VP, IR, VR のみを出力するような初期値とした。

表 2 初期記号出力確率

	D	P	ID	IP	VP	R	IR	VR
実現	0.3	0.3	0.0	0.0	0.0	0.3	0.0	0.0
否定	0.0	0.0	0.2	0.2	0.2	0.0	0.2	0.2

状態遷移確率の初期値は、学習に用いたデータにより決定した。各作曲家の楽曲に対して、暗意実現分析を行い、シンボルの分布を算出した (表 3)。いずれの作曲家も暗意が実現するシンボルである D, P, R の合計値はいずれの作曲家も約 40%であった。そのため全てのモデルにおいて各状態の状態遷移確率の初期値は (0.4, 0.6) とした。

4.2 学習データと評価方法

HMMのパラメータ学習に用いたコーパスはすべて MusicXml で記述されたデータである。本研究では、学習に用いたデータを本著者の1人が手作業で作成した。作成にあ

表 3 各シンボルの割合 (%)

	D	P	R	ID	IP	VP	IR	VR
J.S.Bach	0.9%	39.4%	2.2%	27.7%	28.6%	0.3%	0.2%	0.2%
L.v.Beethoven	5.3%	30.9%	8.1%	17.4%	31.0%	2.5%	8.1%	2.3%
F.F.Chopin	10.1%	26.8%	5.6%	18.5%	35.3%	2.0%	5.6%	1.1%
N.G.Kapustin	4.8%	34.8%	4.7%	15.0%	37.0%	1.5%	1.5%	0.1%

たつて、本研究の分析対象は隣り合う 2 音間の音程のみであるため、コーパス作成時には音価を無視したメロディのみの楽譜を作成した。

コーパスに用いた楽曲は J. S. Bach の『6つのパルティータ』より 10 曲, L. v. Beethoven のソナタより 10 曲, F. F. Chopin の『前奏曲』より 10 曲, N. G. Kapustin 『24の前奏曲より』8 曲である。これらの作曲家を選んだ理由として、時代や地域の離れた作曲家や逆に近い作曲家に対する考察が可能になると考えたためである (表 4)(図 3)。

HMM では、時系列情報を観測記号系列とする。単純に音列を観測記号系列とすると、出力記号数が膨大になりモデルの学習が困難になる、隠れ状態を解釈が困難になるという問題が生じてしまう。そこで、暗意実現分析を前処理として行うことで、パラメータ数を抑えることができ、さらに、隠れ状態の解釈が容易になる。

暗意実現分析は、隣り合う 3 音を分析対象としている。本研究では、観測記号列の先頭から順に 1 音ずつ移動した 3 音組を各分析対象としている。そのため、観測記号列を暗意実現分析した際に、作られる記号列の長さは元の記号列より 2 つ短くなる。

HMM では、観測記号列が長い場合には、パラメータの学

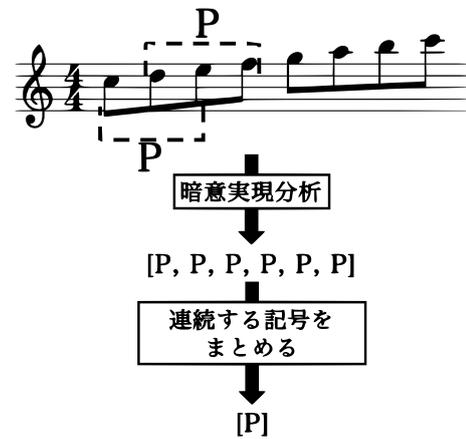


図 4 観測記号列の短縮

習を行えなくなる可能性がある。そのため、長い観測記号系列を学習するには、可能な限り短くする必要がある。スケールやアルベルティ・バスに対し、暗意実現分析を行うと、同一の記号が連続してしまう場合がある。このような場合には、暗意実現分析によって得られた記号列を短くするために、連続する同一の記号列を 1 つの記号とみなした (図 4)。

作曲家識別の評価は Leave-one-out 交差検定法を用いて行った。Leave-one-out 交差検定法とは交差検定法の一つで、データを 1 つずつに分け、データの個数と同じ回数だけモデルの作成と評価を行う方法である。本研究では、各作曲家のデータが 10 件程度であるため、この検定法を採用した。Leave-one-out 交差検定法による正解率はテストセットの正答数/テストデータの総数で与えられる。評価用のデータに対し、学習用データによって作成したモデルとその他の作曲家の楽曲を学習したモデルの計 4 つの学習済みモデルを用いて正解率を算出した。作曲家識別の方法は 2.2 節の Pallastri らに従っており、未知のメロディに対して、最も高い生成確率を与える作曲家モデルを未知のメロディが属する作曲家モデルとした。

5. 評価結果と考察

4 章で行なった実験の結果を示す (表 5)。作曲家ごとの推測結果の曲数と正解率を表に示す。各行は楽曲の作曲家を表し、各列はモデルの推定した作曲家を表す。

未知データに対して、最も識別率の高いモデルは J. S. Bach の楽曲を学習したモデルであり、90%の識別率であった。また、N. G. Kapustin の楽曲を学習したモデルの識

表 4 作曲家の詳細

J. S. Bach (1685 - 1750)	活動地域: ドイツ バロック派
L. v. Beethoven (1770 - 1827)	活動地域: ドイツ 古典派 - ロマン派
F. F. Chopin (1810 - 1849)	活動地域: ポーランド, フランス ロマン派
N. G. Kapustin (1937 -)	活動地域: ロシア 近代

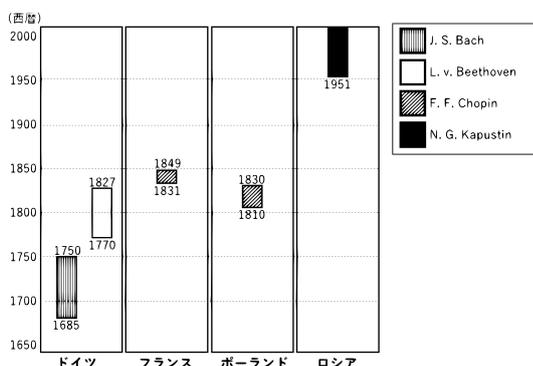


図 3 作曲家年表

表 5 推測結果詳細と作曲家別正解率 (%)

	Bach	Beethoven	Chopin	Kapustin	正解率
Bach	9	0	0	1	90%
Beethoven	2	4	1	2	44%
Chopin	2	3	5	0	50%
Kapustin	0	2	0	6	75%

別率は 75%, F. F. Choin の楽曲の識別率は 50%, L. v. Beethoven の楽曲の識別率は 44%であった。J. S. Bach の楽曲を N. G. Kapustin の楽曲であると誤認識するが, N. G. Kapustin の楽曲を J. S. Bach の楽曲であると誤認識することは無いというように, 識別結果は対称ではない。識別率の平均は約 64%であり, 同じくメロディのみを用いて作曲家識別を行った Pollastri らの識別率である 42%を上回った。

実験における識別結果について考察を行う。誤って識別した楽曲の多くは, 正解の作曲家に比べ, 古い時代の作曲家であることが多かった。これは, 作曲方法が時代によって進歩しているため, 年代の早い作曲家の作品は年代の遅い作曲家の作品と推定されず, 年代の遅い作曲家の作品は年代の早い作曲家の作品と推定されたと考えられる。また, Pollastri らの識別率を上回ったことに関して, Pollastri らの提案したモデルで提案されている観測記号よりも種類が少なかった。また, 暗意実現モデルに基づく観測記号は相互に排他的であるため, 識別制度が向上したと考えられる。このことから, 暗意実現モデルは作曲家識別という問題に対して有用である可能性がある。一方, 本実験で用いた, 各作曲家の楽曲は同一の形式であった。そのため, 作曲者らしさを表現するモデルとしては不十分であると考えられる。

6. おわりに

本研究では, 同一作曲家の作品において暗意の実現, 否定の組み合わせは類似するという仮定の下, 暗意実現モデルに基づく作曲者識別を行う方法について述べた。暗意実現モデルに基づく HMM を作成するために, 隠れ状態が暗意の実現, 否定であると仮定し評価実験を行なった。提案手法を用いた実験では, 先行研究に対し識別率が向上した。これは, 暗意実現モデルによる作曲者識別が有用である可能性を示唆している。今後の課題としては次のようなものが挙げられる。学習データに関しては, 各作曲家の楽曲を増やすことが挙げられる。本稿で用いた楽曲データは同一作曲家の楽曲の形式が同一であったために, 識別率が向上したと考えられるからである。モデルの改良に関しては, 状態数を増やすことが挙げられる。本稿では, 暗意実現モデルに基づき隠れ状態を 2 つとしたため, 状態の解釈が容易だったが, 隠れ状態を増やした際には, 異なる観点からの解釈が必要であり, メロディの分析を行う上で, 適切な状態数を決定することは重要な課題である。

謝辞 研究を通じて, 議論をしていただいた寺井あすか准教授 (公立はこだて未来大学) に感謝いたします。本研究は JSPS 科研費 16H01744, 26280089 の助成を受けたものです。

参考文献

- [1] David Cope, “Signatures and Earmarks: Computer Recognition of Patterns in Music.” *Melodic Similarity: Concepts, Procedures, and Applications (Computing in Musicology 11)*, ed Walter B. Hewlett and Eleanor Selfridge-Field (Cambridge: MIT Press), pp. 129-138.(1998).
- [2] Narmour, E. *The Analysis and Cognition of Basic Melodic Structure: The Imlication-Realization Model*, The University of Chicago Press(1990).
- [3] 箱田裕司, 都築誉史, 川畑秀明, 萩原滋, *認知心理学*, p. 56, (2010).
- [4] 長谷川隆, 西本卓也, 小野順貴, 嵯峨山茂樹, *楽譜情報からの作曲家らしさ認識のための音楽特徴量の提案*, *情報処理学会論文誌 Vol. 53 No. 3*, pp. 12041215 (2012).
- [5] 石桁真礼生, 末吉保雄, 丸田昭三, 飯田隆, 金光威和雄, 飯沼信義, *楽典-理論と学習*, 音楽之友社 (2001).
- [6] ヤン・ラルー, 大宮真琴: *スタイル・アナリシス*, 音楽之友社, p. 44, (1988).
- [7] 北研二, 辻井潤一編, *言語と計算 (4) 確率的言語モデル*, pp. 101-118, (1999).
- [8] Meyer, L. B. : *Style and Music*, The University of Chicago Press (1989).
- [9] 松原正樹, 東条敏, 平田圭二, “音楽理論 GTTM に基づく木構造を用いた旋律の認知的類似度の導出 パッサカリア BWV582 パッサカリアとフーガの分析を例に”, *人工知能学会全国大会 2014, May*, (2014).
- [10] Pollastri, E. and Simoncelli, G. : *Classification of Melodies by Composer with Hidden Markov Models*, *WEDELMUSIC' 01*, pp. 88-95, (2001).
- [11] 東条敏, 平田圭二, *音楽・数学・言語-情報科学が拓く音楽の地平線*, p. 113, (2017).
- [12] 矢澤櫻子, *音楽理論暗意実現モデルに基づく楽曲解析に関する研究*, 筑波大学, 博士論文 (2016).