

統計的学習に基づく音楽理論 σ GTTM: 局所的グルーピング境界の検出

三浦右士^{†1} 浜中雅俊^{†2} 平田圭二^{†3} 東条敏^{†4}

^{†1} 筑波大学第三学群工学システム学類

^{†2} 筑波大学大学院システム情報工学研究科

^{†3} NTT コミュニケーション科学基礎研究所

^{†4} 北陸先端科学技術大学院大学

本稿では、音楽理論 Generative Theory of Tonal Music (GTTM) と、統計的学習を組み合わせた音楽理論 σ GTTM の構築を目指して、まずグルーピング境界の検出に取り組んだ。我々はこれまで、GTTM を計算機実装用に拡張した exGTTM を提案した。しかし exGTTM で正しい分析結果を得るためには、適切なパラメータを曲ごとに手動で設定しなければいけない困難な作業が必要であった。本研究では、局所的なグルーピング境界の自動検出をする際、データの集合を法則化する数学的手法である決定木によって、ルールの優先度を求めることでルールの競合が起こらないようにした。また、不確実性を含む事象の予測が可能な Bayesian Network によって、EM アルゴリズムによる学習をすることでグルーピング境界の判定基準の曖昧さを扱うことを試みた。実験の結果、本手法を実装した検出器はベースラインでの exGTTM の性能を上回ることを確認した。

Music Theory based on Statistical Learning σ GTTM: Detection of Local Grouping Boundary

Yuji Miura^{†1} Masatoshi Hamanaka^{†2} Keiji Hirata^{†3} Satoshi Tojo^{†4}

^{†1} University of Tsukuba, College of Engineering Systems

^{†2} University of Tsukuba, Graduate School of Systems and Information Engineering

^{†3} NTT Communication Science Laboratories

^{†4} Japan Advanced Institute of Science and Technology

This report describes σ GTTM which combine the generative theory of tonal music (GTTM) with statistical learning. We previously described exGTTM which extended GTTM for computer implementation. Although exGTTM has adjustable parameters, these parameters have to be set manually. We solve competition of rule by determining the priority of each rule with decision tree which is a model of decisions and their possible consequences. Moreover, we solve ambiguity of local grouping boundary decision by EM learning with Bayesian Network which able to predict the uncertain phenomenon. Solving those problems, we realize automatic detection of local grouping boundary. Experimental results showed that the performance of σ GTTM outperformed a baseline performance of exGTTM.

1 はじめに

本研究では、音楽理論と統計的学習を組み合わせた音楽理論 σ GTTM の構築を目指して、まずは、統計的学習によって局所的なグルーピング境界の検出が可能であることを示す。本手法の特徴の1つ目は、音楽理論によって適切に抽象化された学習データを用いることである。2つ目の特徴は、統計的なデータを利用することで、曖昧性を持つ音楽の解釈を可能とすること

である。

音楽理論とは、音楽が持つ多様な表現や概念を、音楽に関する専門的な知識、経験、技能を利用して分析、解釈する方法論であり、これまでに多くの音楽理論^{1)~3)}が提案されてきた。この音楽理論を計算機上に実装することができれば、高度な音楽的解釈を容易にすることができる。本研究の最終的な目標は、音楽の専門的な知識に乏しいユーザでも、ユーザ自身が思い描いた通りの音楽的表現が出力可能な音楽シ

システムを実現することである。

音楽理論を用いる処理の一例にメロディ分割があるが、本研究ではこれを扱う。従来のメロディ分割手法^{4)~5)}の多くは、音楽理論に基づくものが多かった。しかしこれらの手法には問題点があり、例えば D. Temperly の The Melisma Music Analyzer⁴⁾ や、浜中らの exGTTM⁵⁾ は、様々な音楽的特徴をパラメータ化することでメロディ分割を可能としているが、そのパラメータを手動で調整しなければいけない問題があった。

一方、音楽理論を用いずにメロディ分割をするためには、生の楽譜を入力としてメロディ分割結果を出力とする関係を、識別問題と考えることで、統計的に学習する手法が考えられる。しかし、生の楽譜をそのまま取り扱う場合には、学習データの組み合わせが膨大な数になってしまう。このため、学習データに存在しなかった組み合わせの出現確率が 0 になってしまうため、学習が困難になるというスパースネスの問題が起きてしまう。

そこで本研究では、音楽理論と統計的学習を組み合わせた σ GTTM の構築を目指し、その第一段階としてメロディ分割を実現する局所的な境界の検出器を実装した。具体的には、生の楽譜に音楽理論を適用して適切にデータの抽象化をすることで、学習データの組み合わせの数を減らし、その上で統計的学習をすることで、メロディが分割される境界を自動的に検出した。

検出器を計算機上に実装し、exGTTM で用いた 100 曲の学習データ⁶⁾ について実験をした結果、ベースラインでの exGTTM の性能を上回ることを確認した。

2 音楽理論 σ GTTM

本節では、2.1 節で音楽理論として GTTM⁶⁾ を選択した理由とその特徴について述べ、2.2 節で GTTM を計算機実装用に拡張した exGTTM⁵⁾ の特徴と問題点について述べる。それらを踏まえたうえで、2.3 節で本研究が目指す σ GTTM について述べる。

2.1 音楽理論 GTTM

我々は、音楽理論の中の一つとして、Lerdahl と Jackendoff の提案した Generative Theory of Tonal Music (GTTM) を選択し、計算機上への実装を試みている。

音楽理論を計算機上に実装する難しさは、一般に音楽は多様な解釈が可能であり、曖昧性を内在しているため、音楽理論も必然的に曖昧さ

を持つことである。また、多くの音楽理論は人に説明することを目的としているので、計算機上への実装が考慮されていない点も問題となる。

GTTM は、他の多くの音楽理論と異なり、楽曲中に現れる音楽的な構造や関係を詳細に検討して得られた知識や手順を、ルールとして記述している特徴がある。これにより GTTM は、音楽知識を計算機上のプログラムとして記述するのに、比較的適した音楽理論であると考えられる。

GTTM は、グルーピング構造分析、拍節構造分析、タイムスパン簡約、プロロンゲーション簡約の 4 つのサブ理論から構成されている。この中で、メロディ分割に対応するものがグルーピング構造分析である。

グルーピング構造分析は、連続したメロディをフレーズやモチーフなどのグループに分割するとともに、各グループの階層構造を決定する。これにより分割されるグルーピング境界は、構造が成立するために必要な条件や制約を規定するグルーピング構成ルール (Grouping Well-Formedness Rules, GWFR) と、複数の構造が構成ルールを満たす場合にどれが好ましいかを示すグルーピング選好ルール (Grouping Preference Rules, GPR) の 2 つのルールによって求める。このうち、計算機上に実装する際に問題となるのは GPR である。GPR はさらに、階層的な構造のうち最も低次な (局所的な) グルーピングに対応するルール (GPR1,2,3) と高次なグルーピングに対応するルールの 2 種類に分けられる。この 2 種類のルールを適用することで、階層的なグルーピング構造を得ることができる。

2.2 音楽理論 exGTTM

浜中らはこれまでに、GTTM を計算機実装用に拡張した音楽理論 exGTTM を提案した。exGTTM では、楽曲の正しい解釈は複数ある前提のもとで、パラメータを導入して曖昧さをできる限り排除することを方針とした。そして、タイムスパン木を獲得するシステム ATTA⁵⁾ によって、exGTTM を計算機上に実装をした。

しかしこの方針のために、ATTA では複数のパラメータの手動設定という困難な作業が必要であった。この問題を解決するために、タイムスパン木の安定度および拍節構造の安定度に基づき、ATTA のパラメータの値の最適化する FATTA⁷⁾ を提案したが、ATTA の手動設定の性能を超えることはできなかった。この原因としては、パラメータの数が多すぎてパラメー

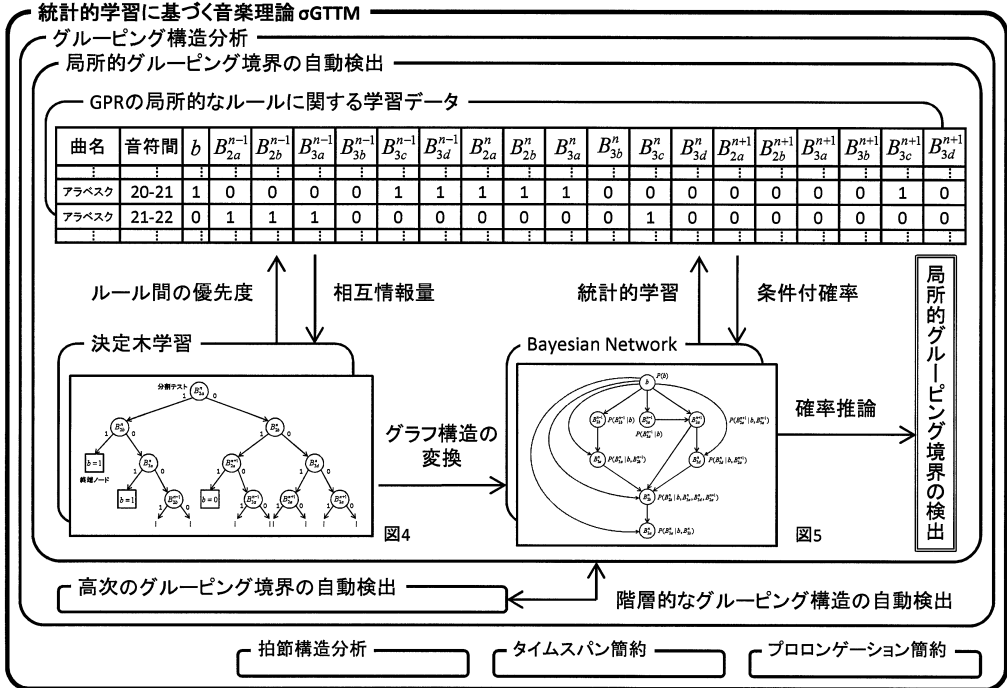


図 1 σ GTTM の全体図

タ間の独立性が失われ、パラメータの最適化が難しくなってしまったことが考えられる、

2.3 統計的学習に基づく音楽理論 σ GTTM

σ GTTM における局所的な境界の検出器を設計するに当たっては、楽曲構造の特徴には楽曲ごとに多少の変化はあるが、取り扱う楽曲全体には同じ傾向が存在しているという前提をもつとする。そして、GTTM を計算機上に実装する際に生じる問題を、統計的手法を用いて自動的に解決することを方針としている。

本稿では、局所的なグルーピング境界の自動検出器を実装する。その際に生じるルールの競合の問題を、データの集合を法則化する数学的手法である決定木⁸⁾によってルール間の優先度を求めることで解決する。さらにその決定木を、不確実性を含む事象の予測が可能な Bayesian Network⁹⁾に変換し、EM アルゴリズムによる学習をすることで、楽曲構造の特徴の違いを解決することを試みた。

図 1 は本研究が目指す σ GTTM の全体図である。本稿では、3 節で σ GTTM の一部である、学習データから局所的なグルーピング境界を自動検出する方法について述べ、4 節と 5 節でその具体的な手法である決定木と Bayesian Network についてそれぞれ述べる。

3 局所的グルーピング境界の検出

本節では、3.1 節で GPR の局所的なルールに関する学習データについて述べ、3.2 節でそれを用いて局所的なグルーピング境界を検出する方法について述べる。

3.1 学習データ

図 2 は GPR の局所的なルールの詳細である。統計的学習をするに当たっては、このような GPR の局所的なルールが実際に楽譜上に適用され、正しい境界が求められている学習データが必要になる。その学習データとして我々は、exGTTM を評価する際に用いた正解データ⁶⁾を採用する。

この正解データは、GTTM をよく理解している 1 人の音楽家が、クラシック曲から 8 小節の長さ (8 小節で区切りの悪い場合は 8 小節以上で区切りの良いところまでとした) で切り出した 100 個のメロディの楽譜データを、GTTM に基づき手作業でグルーピング構造分析したものである。さらに、この正解データに明らかに間違った解釈でないことを、3 人の GTTM の専門家がクロスチェックしている。

GPR 1	“単音の非グループ化”:単音をグループとすることは避ける
GPR 2	“音の近接箇所”:4つの連続した音符列 [n1, n2, n3, n4] が以下の条件を満たす場合, n2 - n3 間にそのルールが適用される。 (2a) “スラー/休符”: n2の終わりからn3の始まりまでの時間間隔が, n1の終わりからn2の始まりおよびn3の終わりからn4の始まりまでの時間間隔よりも長い。またスラーの終わりの音はスラーの中の音より短くなる。 (2b) “発音間隔”: n2の始まりからn3の始まりまでの時間間隔が, n1の始まりからn2の始まりおよびn3の始まりからn4の始まりまでの時間間隔よりも長い。
GPR 3	“音の断絶箇所”:4つの連続した音符列 [n1, n2, n3, n4] が以下の条件を満たす場合, n2 - n3 間にそのルールが適用される。 (3a) “音高差”: n2 - n3 間の音高差が n1 - n2 間および n3 - n4 間の音高差より大きい。 (3b) “強弱”: n2 - n3 間で音の強弱の変化があり, n1 - n2 間および n3 - n4 間ではそれが無い。 (3c) “articulation”: n2 - n3 間で articulation pattern の変化があり, n1 - n2 間および n3 - n4 間ではそれが無い。 (3d) “音長”: n2 - n3 間が異なった音長をもち, n1 - n2 間または n3 - n4 間が同じ音長である。

図 2 GPR の局所的なルールの詳細

3.2 境界の検出

図 3 は、学習データの一部である局所的なグルーピング構造の具体的な分析例である。このような楽譜上でのルールの適用分布が分かっている状態から、正解データと同じ局所的なグルーピング境界を、統計的学習により自動的に検出する。

3.2.1 境界の検出における問題点

GPR の局所的なルールから、局所的なグルーピング境界を検出する際には、大きく分けて二つの問題が考えられる。

まず一つ目は、グルーピング境界を検出する際に、ルールの競合が起きてしまうことである。図 3 の分析例を見ると、23 番目の音符と 24 番目の音符の間（以下 23-24 音符間などとする）に GPR3a が適用され、24-25 音符間に GPR2a が適用されているが、この両方を境界とすることは、GPR1 によって避けるべきことと定められている。したがって、この場合は GPR2a と GPR3a の一方しか採用されない。分析例では

GPR2a が採用されているが、どちらのルールを採用するかを選ぶ方法は GTTM では明確に規定されていない。

二つ目は、ある音符間に GPR の局所的なルールが適用された際に、その音符間が必ずしもグルーピング境界になるわけではないことである。図 3 の分析例を見ると、5-6 音符間と 10-11 音符間、15-16 音符間は共に GPR2a、GPR2b が適用され、その音符間がグルーピング境界と判定されているが、26-27 音符間では同様に GPR2a、GPR2b が適用されているにも関わらず、その音符間はグルーピング境界と判定されていない。そして、この問題を解決する方法も GTTM では明確に規定されていない。

3.2.2 境界の検出における問題点の解決法

境界の検出において問題が起こってしまう具体的な原因としては、ルール間での優先度が明確に決まっていないことやグルーピング境界の判定基準が曖昧であることが挙げられる。そこで我々は、ルール間での優先度を明確に求

局所的グルーピング境界

↓

音符番号→ 1 2 3 4 5 | 6 7 8 9 10 | 11 12 13 14 15 | 16 17 18 19 20 |

適用GPR→

5 21 22 23 24 | 25 26 27 28 29 30 31

図 3 局所的なグルーピング構造の分析例 (J.F.F.Burgmuller 「アラベスク」より)

めるために決定木を用い、決定木を Bayesian Network のグラフ構造に変換して、統計的学習をすることにより、グルーピング境界の判定基準の曖昧さの解決を試みる。

4 決定木を用いたルールの優先度判定

決定木⁸⁾は、データ中のある注目する属性（目的属性）に関する重要な知識を、木構造によるルール（条件属性）の組み合わせで表現したものである。決定木では、条件属性の中から適切なルールを一つ選び、そのルールが1か0かによって、データを2つに分割する。この分割を分割テストと呼び、これを繰り返すことで決定木を構築していく。

本節では、4.1節で決定木を構築する際に用いるデータの選定について述べ、4.2節でデータから分割テストをする具体的な手法について述べる。そして4.3節では、実際に決定木の構築と調整をする手法を述べる。

4.1 データの選定

データから目的に合った決定木を構築するためには、目的に合ったデータの種類の選定が重要である。ルール間の優先度を求めるという我々の目的に対しては、ある音符間に注目したとき、その音符間に GPR の局所的なルール (GPR1,2,3) がそれぞれ適用されているかが重要であり、また、GPR 1 を考慮すると、その音符間の1つ前の音符間と1つ後ろの音符間のルールの適用状況も重要となる。ここではデータの種類を B_{2a}^n という形で定義する。上付き文字は一つ前の音符間を $n-1$ 、一つ後ろの音符間を $n+1$ 、真ん中の音符間を n と表し、下付き文字は GPR の種類を表すとする。全てのデータの種類を書き出すと B_{2a}^{n-1} , B_{2b}^{n-1} , B_{3a}^{n-1} , B_{3b}^{n-1} , B_{3c}^{n-1} , B_{3d}^{n-1} , B_{2a}^n , B_{2b}^n , B_{3a}^n , B_{3b}^n , B_{3c}^n , B_{3d}^n , B_{2a}^{n+1} , B_{2b}^{n+1} , B_{3a}^{n+1} , B_{3b}^{n+1} , B_{3c}^{n+1} , B_{3d}^{n+1} となる。この18個のルールの有無（ルールが適用されていれば1、そうでなければ0の値を持つとする）を条件属性とし、グルーピング境界の有無 (b で表す、境界になれば1、そうでなければ0の値を持つとする) を目的属性とするデータを用意した。

図2に示されているように、ある音符間にルールが適用された場合は、その前後の音符間では同じルールは成り立たない。例えば、GPR3a は「 n の音高差が $n-1$ および $n+1$ の音高差より大きい」というルールなので、 $B_{3a}^n = 1$ の時、必ず $B_{3a}^{n-1} = 0$ かつ $B_{3a}^{n+1} = 0$ となる。

4.2 決定木の分割テスト

決定木の適切な分割テストを求める際の評価関数には、目的に応じて様々なものが考えられる。我々はその中で、判別問題によく利用される相互情報量に基づく手法を選択した。

相互情報量は目的属性 b に関する条件属性の重要度を比較するのに有用であり、相互情報量が最も大きい条件属性のルールを用いて、分割テストをすることで、より性能の高い決定木を構築することができる。

相互情報量を求める手法を具体的に説明する。まず、あるデータ集合 S の事象 X に関する「あいまいさ」を、エントロピ関数を用いて次式のように定義する。

$$H(S) = H(X) = - \sum_{j=1}^k p_j \log_k p_j$$

ここで、 p_j は X の k 種類ある事象 a_1, \dots, a_k のうち、事象 a_j ($1 \leq j \leq k$) の出現率とする。ただし、 $a_i \cap a_k = \emptyset$ ($i \neq j$) であるとする。

表1 b と B_{2a}^n の出現率の関係

出現率	$B_{2a}^n = 1$	$B_{2a}^n = 0$	合計
$b = 1$	0.10	0.14	0.24
$b = 0$	0.04	0.72	0.76
合計	0.14	0.86	1.00

今回の学習データを例として考えると、 b を X 、 B_{2a}^n を $Y1$ とし、 b と B_{2a}^n の出現率の関係 (表1) を用いて、

$$H(X) = -0.24 \log_2 0.24 - 0.76 \log_2 0.76 = 0.79$$

となり、同様にして、

$$H(X|Y1 = 1) = 0.82$$

$$H(X|Y1 = 0) = 0.63$$

が求まり、

$$\begin{aligned} H(X|Y1) &= 0.14 \times H(X|Y1 = 1) \\ &\quad + 0.86 \times H(X|Y1 = 0) \\ &= 0.66 \end{aligned}$$

となる。このエントロピ関数値の減少量、

$$H(X) - H(X|Y1) = 0.13$$

が $Y1$ の X に関する相互情報量である。

4.3 決定木の構築と調整

決定木は、相互情報量に基づいた最適な分割テストによって、学習データを2つに分割し、その分割データに対しても繰り返し分割テストをすることで構築する。この分割の終了条件については、分割データ数が全学習データ数に

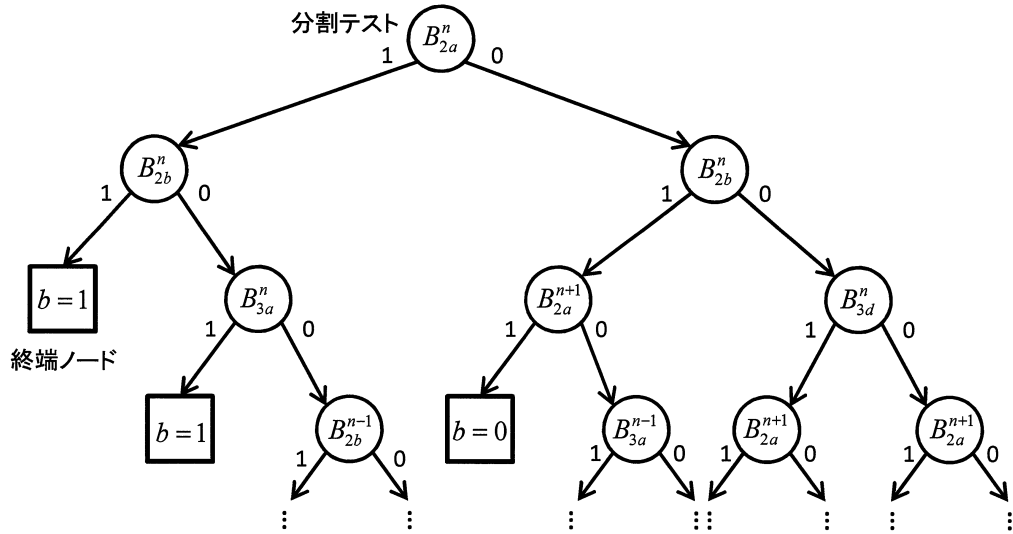


図4 完成した決定木の一部

対して十分小さい場合とした．そして，その決定木の各終端ノードでは，そのノードに分類されるデータから，目的属性の値が決定される．

また，決定木を目的属性の値を予測するツールとして利用する場合は，予測精度が高くなるように木の大きさを調整する枝刈りの作業をする必要がある．我々は，ルール間の優先度を求めるために決定木を用い，決定木自体の性能を向上させる必要性はないので，予測精度が向上するような枝狩りはしなかった．代わりに，できるだけ大きな決定木を構築したあとに，グルーピング境界の予測精度が変わらない範囲で決定木を簡略化することで，木の大きさを調整した．

図4は，調整を行って完成した決定木の一部を示している．この決定木の上部に存在するルールほど，より早く分割テストとして採用されているので，より重要なルールであると言える．例えば図4では， B_{3a}^n より B_{2b}^n が， B_{2b}^n より B_{2a}^n のほうがルール間の優先度が高いことが読み取れる．

5 BNとグルーピング境界の検出

Bayesian Network (以下BNとする)⁹⁾は，複数の確率変数の間の定性的な依存関係をグラフ構造によって表し，個々の変数の間の定量的な関係を条件付確率で表した確率モデルである．確率モデルとしては，確率変数，確率変数間の依存関係を表すグラフ構造，条件付確率の集合によって定義される．

本節では，確率変数として，決定木で用いた条件属性と目的属性のルールの内容をそのまま事象として定義し，その可能性に関して0から1の間の確率値をとるとする．5.1節でこの確率変数を用いてBNのグラフ構造を構築する手法について述べ，5.2節で統計的学習によりグラフ構造の条件付確率を求める手法を述べる．そして5.3節では，BNの実装とグルーピング境界を検出する具体的な手法を述べる．

5.1 BNのグラフ構造の構築

BNでは，確率変数はノードとして，確率変数間の依存関係は向きを持つ有向リンクで図示する．例えば，確率変数 X_i, X_j の間の条件付依存性は $X_i \rightarrow X_j$ と表す．リンク先のノードを子ノード，リンク元のノードを親ノードと呼び，この場合は X_j が子ノード， X_i が親ノードとなる．親ノードが複数あるとき，子ノード X_j の親ノードの集合を $Pa(X_j)$ とすると， X_j と $Pa(X_j)$ の間の依存関係は， $P(X_j|Pa(X_j))$ という条件付確率によって表される．このようにして各子ノードと親ノードの間にリンクを張って構成したBNによって，これらの変数の間の確率的な依存関係をモデル化できる．

BNでは，グラフ構造を統計的学習により求める手法も存在するが，構造の正確な評価ができないことをはじめ，未解決の問題が多く存在する．そこで我々は，BNのグラフ構造を図4の決定木から求めるため，以下のようなアルゴリズムを考えた．

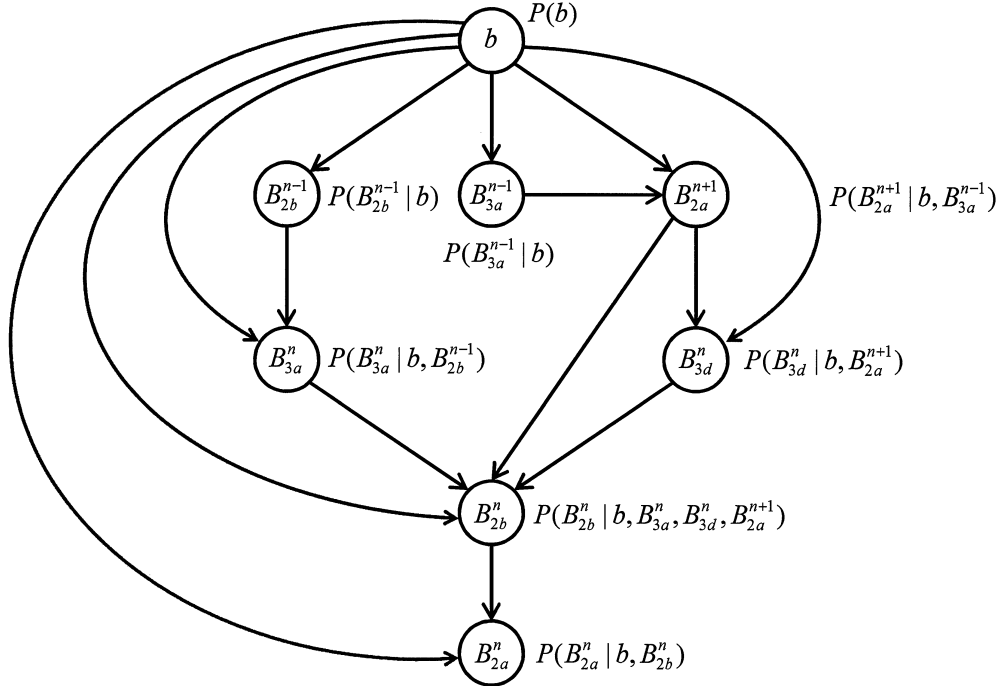


図5 決定木から変換した Bayesian Network のグラフ構造

まず、グルーピング境界の有無を判定する際に事後確率を用いることを考慮して、矢印を逆向きにする。次に確率変数間の独立性を保つために、重複しているノードをまとめる。最後に目的属性 b のノードが、他の全てのノードの親ノードとなるようにリンクをつなげる。

これらの操作によって、決定木から変換した BN のグラフ構造を図 5 に示す。なお、決定木全てを BN に変換すると、BN が非常に複雑になり、かえって性能が低下してしまうので、今回は決定木の上部に存在する 7 つのルール ($B_{2b}^{n-1}, B_{3a}^{n-1}, B_{2a}^{n+1}, B_{3a}^n, B_{3d}^n, B_{2b}^n, B_{2a}^n$) を用いて、BN のグラフ構造を構築した。

5.2 BN の統計的学習

条件付確率は、学習データを用いて統計的に学習することで求めることができる。条件付確率を求めることで、不確実性を含む事象の予測、つまり、局所的なグルーピング境界の有無の判定をすることができる。

学習アルゴリズムには様々なものが考えられるが、BN では、隠れたパラメータが存在するときに最尤推定をするための汎用手法である EM アルゴリズムを用いる。

5.3 BN の計算機上への実装

BN の計算機上への実装と統計的学習には、佐藤らが考案した PRISM¹⁰⁾ を用いた。

PRISM は論理プログラムを基礎として、BN や隠れマルコフモデルなどの確率モデルを包含する汎用の統計モデル記述言語であり、その処理系は EM アルゴリズムに基づくデータからのパラメータ学習機能を備えている。

我々は、図 5 と同様の BN のグラフ構造を PRISM 上に実装し、EM アルゴリズムに基づく最尤推定によって、BN の条件付確率を求めた。そして、条件属性のすべての組み合わせについて、目的属性 b の事後確率を、hindsight 推論¹¹⁾を用いて求めた。求めた事後確率の値が、0.5 以上の場合には、グルーピング境界があると判定し、0.5 未満の場合とその組み合わせのデータが存在しない場合には、グルーピング境界がないと判定した。例えば、

$$B_{2a}^n = B_{2b}^n = 1,$$

$$B_{2b}^{n-1} = B_{3a}^{n-1} = B_{3a}^n = B_{3d}^n = B_{2a}^{n+1} = 0$$

の条件属性の組み合わせの場合、 $b = 1$ となる事後確率は 0.92 と求められるので、この条件属性の組み合わせを持つ音符間のデータには、すべてグルーピング境界があると判定する。

6 実験結果

本節では、 σ GTTM の局所的な境界検出器に関する性能評価を、適合率 P (precision) と再現率 R (recall) を組み合わせた F 値で評価する。適合率 P は、システムのグルーピング境界のうち、正解データのグルーピング境界と一致する割合で、再現率 R は、正解データのグルーピング境界のうち、システムのグルーピング境界と一致する割合である。 F 値の式は、

$$F_{\text{値}} = 2 \times \frac{P \times R}{P + R}$$

となり、適合率 P と再現率 R の値が高いほど、 F 値は高くなる。この F 値が高いほど、そのシステムの性能は高いと言える。

このような評価をするためのデータとしては、3.1節で述べた正解データ⁹⁾を用いる。今回はATTAのパラメータ調整前(ベースライン)の性能と σ GTTMの局所的な境界検出器の性能を同条件で比較評価する関係から、正解データからGPR 6の影響を取り除いたデータを用いて評価実験をした。実験の結果、 σ GTTMの局所的な境界検出器の性能はベースラインのATTAの性能と比べて、 F 値で0.08上回ることを確認した。表2は、この評価実験の結果である。

表2 評価実験の結果 (ATTAはベースライン)

	適合率P	再現率R	F値
σ GTTM (提案手法)	0.68	0.59	0.63
ATTA (従来手法)	0.74	0.43	0.55

7 おわりに

本稿では、我々が目指す σ GTTMの一部である、GTTMのグルーピング構造分析における局所的なグルーピング境界を、統計的学習を用いることで自動的に検出する手法について述べた。本手法は、決定木を用いてルール間の優先度を求めることで、ルールの競合が起こらないようにした。さらに、その決定木をBayesian Networkのグラフ構造に変換し、EMアルゴリズムで学習することで、グルーピング境界の判定基準の曖昧さを解決することを試みた。これらの手法により、局所的なグルーピング境界の自動検出が可能であることを示した。本手法を実装した検出器を用いて実験した結果、ベースラインのATTAの性能を上回ることを確認した。

今後、局所的なグルーピングだけでなく、高次のグルーピングに関するルールを導入することで、階層的なグルーピング構造の自動獲得を実現する。また、GTTMの他の3つのサブ理論(拍節構造分析、タイムスパン簡約、プロロンゲーション簡約)についても、統計的学習を用いて実装することにより、図1の σ GTTM全体を完成させていく。

参考文献

- 1) Cooper, G. and Meyer, L.B.: The Rhythmic Structure of Music, The University of Chicago Press, Chicago (1960).
- 2) Narmour, E.: The Analysis and Cognition of Basic Melodic Structure, The University of Chicago Press, Chicago (1990).
- 3) Temperley, D.: The Cognition of Basic Musical Structures, The MIT Press, Cambridge (2001).
- 4) Temperley, D.: The Melisma Music Analyzer, <http://www.link.cs.cmu.edu/music-analysis/> (2003).
- 5) 浜中雅俊, 平田圭二, 東条敏: 音楽理論 GTTMに基づくグルーピング構造獲得システム, 情報処理学会論文誌, Vol. 48, No. 1, pp. 284-299 (2007).
- 6) F. Lerdahl, and R. Jackendoff: A Generative Theory of Tonal Music. Cambridge, Massachusetts: The MIT Press (1983).
- 7) 浜中雅俊, 平田圭二, 東条敏: タイムスパン木獲得システムの完全自動化, 情報処理学会研究報告, 2007-MUS-71-16, pp. 93-98 (2007).
- 8) 福田剛志, 森本康彦, 徳山豪: “決定木・回帰木”, データマイニング (データサイエンス・シリーズ), 東京, 共立出版, pp. 93-130 (2001).
- 9) 本村陽一, 佐藤泰介: ペイジアンネットワーク不確定性のモデリング技術一, 人工知能学会誌, Vol. 15, No. 4, pp. 575-582 (2000).
- 10) Sato, T. and Kameya, Y.: Parameter learning of logic programs for symbolic-statistical modeling, Journal of Artificial Intelligence Research, Vol. 15, pp. 391-454 (2001).
- 11) 亀谷由隆, 佐藤泰介, 周能法, 泉祐介, 岩崎達也: PRISM: 確率モデリングのための論理プログラミング処理系, 日本ソフトウェア科学学会会誌, Vol. 24, No. 4, pp. 2-22 (2007).