

特徴量軌跡の機械学習に基づく ジャズセッションの自動生成

保利 武志^{1,a)} 中村 和幸^{1,b)} 嵯峨山 茂樹^{1,c)}

概要: 本研究では、統計的に学習可能な枠組みにおいて、人間の演奏者と計算機によるインタラクティブなジャズセッションを実現するための数理モデル及び定式化と演奏生成手法について述べる。即興演奏を主体とするジャズセッションにおいて適切な演奏を選択・生成するために、従来のジャズセッションシステムでは演奏者の演奏意図を推定するためのパラメータを、経験則や心理実験等を介してヒューリスティックに決定していたが、本稿で提案するジャズセッションの数理モデルでは、音楽演奏は音楽特徴量空間の軌跡として表現可能であるという仮説に基づき、リード譜と演奏データのみから各楽器演奏の関係性を統計的に学習することで、演奏状態を推定し、その状態に適した演奏を生成する。本モデルでは、特に利用可能な学習データが限られたデータのスパース性に起因する学習困難な問題に対して、Hidden Markov Model (HMM) を用いたセグメンテーションによる空間量子化・軌跡離散化によって学習可能な確率的状態遷移モデルへの近似を行い、楽器演奏間関係性は Stacked bidirectional Long Short-term Memory (LSTM) 及び Deep Berief Network (DBN) により学習・推定し、推定された各状態に基づく音高遷移の確率分布と確率的文脈自由文法 (PCFG) を用いたリズムパターンによる伴奏楽器演奏を生成する。評価実験の結果、これまで我々が提案してきた通常の LSTM による状態推定とリズム木仮説を用いたリズムパタンの最尤推定による生成と比べ、推定精度の向上及び演奏生成に関する拡張可能性が示された。

Automatic Generation of Jazz Session Based on Machine Learning of Feature Trajectories

HORI TAKESHI^{1,a)} NAKAMURA KAZUYUKI^{1,b)} SAGAYAMA SHIGEKI^{1,c)}

1. はじめに

コンピュータを利用した音楽研究は、現在も活発に報告されている人工知能による芸術分野への適応可能性から、演奏支援や自動作曲、自動採譜、音楽情報検索など様々な観点から行われており、特に大量のビッグデータから深層学習などを用いた演奏特徴の解析・学習も盛んに研究されている。そのような音楽情報処理研究の中で、人間と計算機とが協調演奏するシステムは自動伴奏システムと呼ばれ、特に近年は計算機による計算速度の飛躍的な向上によ

るリアルタイムなセッションも数多く実現されている。

我々はこれまで、指定された楽譜情報に基づき、演奏誤りやテンポ変化、弾き直し、弾き飛ばしに対してもフレキシブルに対応可能な自動伴奏システム'Eurydice' [1], [2] を開発したが、これをさらに発展させ即興演奏にも対応できる自動伴奏システムの実現を目標とし、即興演奏が主体であるジャズを対象としたジャズセッションの数理モデルと、その実現に向けたオフラインシステムを提案してきた [3], [4], [5]。これはピアノの MIDI 演奏データを入力とし、その演奏に適したベース及びドラムスの演奏データを探索、もしくは生成して編集合成し、最終的にピアノトリオとして MIDI 出力するシステムであり、これまで演奏意図を判別するためのパラメータの閾値を経験則や心理実験等を用いてヒューリスティックに決定してきた従来のジャズ

¹ 明治大学
Meiji University, Nakano, Tokyo 164-8525, Japan
a) hori@meiji.ac.jp
b) knaka@meiji.ac.jp
c) sagayama@meiji.ac.jp




図 1 本システムの入出力. 各楽器の演奏は音楽特徴量空間のトラジェクトリとしてモデル化される.

セッションシステム [6], [7], [8], [9], [10] に対して, MIDI 演奏データのみから主楽器演奏者(ピアノ)と伴奏楽器演奏(ベース, ドラムス)との関係を統計的に学習可能な枠組みにおいてモデル化したものである.

図 1 に本システムの入出力関係を示す. 本システムでは音楽演奏は音楽特徴量空間上の軌跡として表現可能であるという仮説に基づき, 楽器間の演奏を軌跡の「絡み(共起)」として統計的に学習することで, 入力特徴量から伴奏楽器の軌跡を推定し, その軌跡に基づいた演奏を生成し出力する. 本研究ではこれまで我々が提案してきた自動ジャズピアノトリオ編集合成システム [5] に対して, 特に演奏状態推定精度向上のための手法と, 演奏生成におけるリズムパターン生成手法の検討を行った.

2. セッションの数理モデル

我々はこれまで統計的に学習可能なセッションの数理モデルとして, 音楽演奏の音楽特徴量空間軌跡モデルを提案してきた. これは, ある点(時刻)における音楽演奏が, 音楽特徴量空間においてその時の演奏状態を表す演奏特徴量ベクトル(音高や音量, テンポ等)によって表現されるとするならば, (ジャズ)演奏者は演奏中その空間を「移動」していると思ふことができ, 結果として音楽演奏は音楽特徴量空間における「軌跡」として観測されるという仮説に基づいている.

これを複数楽器によるセッションモデルへと拡張すると, 良いセッションとは名演奏と呼ばれるような様々なセッションにおいてよく共起し合う軌跡の関係であり, セッションシステムはその関係性を学習することで実現可能であると言える. 従って, 理想的には無限のデータが存在すればその軌跡間の関係を学習することが可能であるが, 実際に統計的に学習可能な枠組みにおいてジャズセッションを実現するためには, よく共起し合う楽器間軌跡の相関関係を現実的なデータ量で計算可能な空間へと落とし込むことが必要となる.

3. 統計的に学習可能なセッションの数理モデルとデータのスパース性に基づく問題点・解決策

軌跡モデルにおいて, 現実的なデータ量から学習するためには主として以下の3つの問題点が挙げられる.

- (1) 音楽特徴量空間の高次元性
- (2) 軌跡の連続性
- (3) 楽器軌跡間の非線形な関係性

音楽特徴量空間はその性質上音楽演奏が持ちうるあらゆる属性(音高や音量などのノートに関する情報から, アイコンタクトや演奏環境など)を保持する必要があるが, 現実的なデータでその全てを考慮するのは難しい. 本研究では特にジャズ演奏において特徴的であり, 演奏状態を追跡するために有効なパラメータを選択することで特徴量空間の軸の設計を行った.

また同様にデータ量の問題から, 連続的な演奏特徴量軌跡を推定・生成するためには, 補間もしくは離散化による近似を行う必要がある. 時間的に変化する演奏特徴量軌跡を近似するには, 同様に時間変化する, クラスタリング等によりセグメント化された空間・軌跡において, その(部分空間の)状態を推定可能なモデルによって近似することが望ましい. 本研究では各楽器軌跡別に, 時系列性を持つ確率的状態遷移モデルとして近似可能な Hidden Markov Models (HMMs) によって軌跡近似を実現し, またその軌跡間の相関関係を Deep Neural Networks (DNNs) を用いて学習した.

3.1 音楽特徴量空間の高次元性

我々はこれまで, 小節単位で抽出可能な 68 の特徴量 (Style parameters) を定義し, これを音楽特徴量空間の軸として設計した. 各特徴量は先行研究及びジャズ演奏家の意見を基に, 主として各小節における音高や音数などの原特徴量と, 一つ前の小節または1曲全体に対する比から成り, 動的特徴量を含むベクトルとすることで, 明示的に演奏変化を表現するよう構成されている.

3.2 軌跡の連続性

音楽特徴量空間においてある入力軌跡から他楽器の演奏軌跡を生成するためには, 有効な音楽演奏データを補間または離散化し, その関係性を学習する必要がある. 本システムにおいては, 伴奏楽器の特徴量空間をクラスタリングすることによって実現した. 特に, 音楽演奏軌跡は時系列的な意味を無視できないため, 本研究では時系列性を考慮しながらセグメント可能なモデルとして連続混合 HMM を用いたクラスタリングによる近似を行った.

HMM の学習アルゴリズムは一般に EM アルゴリズムが用いられることが多いが, EM アルゴリズムは補助関数法

の特殊なケースとして考えることもできる。HMM では観測系列 x と隠れ状態系列 z , パラメータ θ を用いて,

$$p(x; \theta) = \sum_z p(x, z; \theta), \quad (1)$$

を最大化するパラメータを考える。 N 個のデータからなる対数尤度関数を考えると,

$$\sum_{i=1}^N \log p(x_i; \theta) = \sum_{i=1}^N \log \sum_{z_i} p(x_i, z_i; \theta), \quad (2)$$

となるが, これは Jensen の不等式から,

$$\log \sum_{z_i} \phi_{z_i} p(x_i, z_i; \theta) \geq \sum_{z_i} \phi_{z_i} \log p(x_i, z_i; \theta) \quad (3)$$

$$= : G(\theta, \phi) \quad (4)$$

$$s.t. \sum_c \phi_c = 1, \quad (5)$$

となり, 次のように θ と ϕ について交互に最大化を行うことでパラメータの更新が可能となる。

$$\phi^* = \arg \max_{\phi} G(\theta, \phi), \quad (6)$$

$$\theta^* = \arg \max_{\theta} G(\theta, \phi^*). \quad (7)$$

以上のアルゴリズムから得られたパラメータを用いて, viterbi アルゴリズムにより隠れ状態系列を推定できる。観測される演奏特徴量は各状態が持つ確率分布に応じてクラスタリングされることから, 得られたこれらの隠れ状態は演奏特徴量空間のセグメンテーションによる部分空間であると同時に, 各時刻における演奏状態 (スタイル) を表しているとも解釈できる。

ここで, HMM の表現力は隠れ状態数に依存するが, 学習データ量に対して状態数が多い場合うまく学習が進まない場合があり, また, 逆に少ない状態数による HMM のみでは軌跡を十分に表現できるとは言えない。そこで, さらに各時刻において得られた観測ベクトルと各状態のセントロイドからの偏移を Gaussian Mixture Model (GMM) を用いてクラスタリングすることでモデルの表現力を補完する。

結果として, 軌跡モデルは確率的状態遷移モデルとして統計的に学習可能な枠組みに落とし込むことが可能となり, また HMM によるセグメンテーションによって得られた部分空間とその偏移クラスの利用は軌跡の表現力を高めるだけでなく, 部分空間の局所性を利用した入力特徴量と伴奏楽器特徴量間のロバストなマッピングにも寄与できると期待できる。

本システムでは予備実験結果から, 特徴量空間セグメンテーションのための連続混合 HMM の状態数を 4, 混合数を 4, また偏移ベクトルクラスタリングのための GMM の混合数を 8 とした。




図 2 本システムの Training phase 及び Synthesizing phase. Training phase では楽器間の関係性を学習し, Synthesizing phase では伴奏楽器の即興演奏を生成・合成する。

3.3 楽器軌跡間の非線形な関係性

各楽器の特徴量空間の軸が異なることから, 軌跡間の関係は非線形であると考えるのが妥当である。そこで, 本研究では非線形な特徴量間の時系列関係をモデル化する Long Short-term Memory Recurrent Neural Network (LSTM-RNN)-based な時系列ネットワークを用いて, ピアノの演奏特徴量系列と HMM によって得られるベース・ドラムスの状態系列との関係性を学習し, さらに同様にピアノの演奏特徴量と GMM によって得られた偏移クラスとの関係を Deep Berief Network (DBN) を用いて学習した。

4. Jazz Piano Trio Synthesizing System

軌跡モデルを近似した確率的状態遷移モデルに基づき, 我々は Jazz Piano Trio Synthesizing System (JPTSS) を実装した。本システムは MIDI フォーマットのピアノのみの演奏データを入力として, 適したベース・ドラムスを生成し, 編集合成してピアノトリオ曲として MIDI データを出力するシステムである。

図 2 に本システムのブロックダイアグラムを示す。JPTSS は Training phase と Synthesizing phase から成り, 主として Training phase では軌跡推定のための学習が行われ, Synthesizing phase では学習によって得られたネットワークを用いた軌跡の推定とその推定された軌跡に基づく演奏の生成及び合成が行われる。

4.1 Training phase

Training phase は以下の 6 ステップからなる。

- (1) *Key estimation*
学習データの全小節に対する調の推定。
- (2) *Feature extraction*
小節単位で Style parameters の抽出・計算。
- (3) *Data segmentation*
連続混合 HMM によるベース・ドラムス演奏特徴量空間のセグメンテーション。
- (4) *Performance correlation (coarse)*
Stacked bidirectional LSTM によるピアノの Style parameters と (3.) の他楽器の特徴量空間セグメントクラスとのマッチング学習。

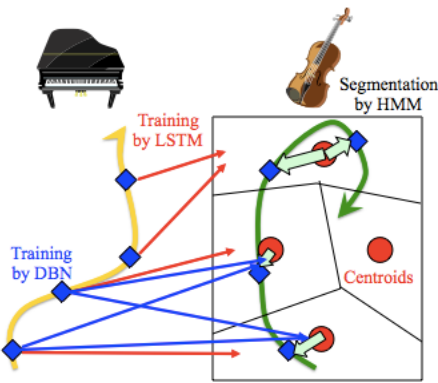


図 3 本システムの学習ネットワーク概要図. LSTM ではピアノの特微量ベクトルの時系列と他楽器の HMM 状態の時間的遷移のマッチングを学習し, DBN では各 HMM 状態のセントロイドからの偏移との関係性を学習する.

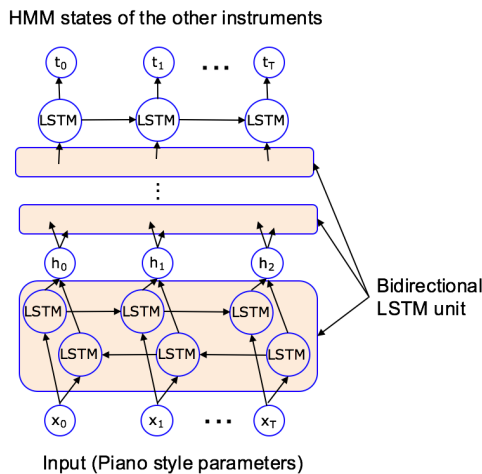


図 4 入力系列に対して前向きと後ろ向きの LSTM を結合する bidirectional 構造をもつユニットを多層重ねるネットワーク.

(5) Clustering of centroid deviation vectors

GMM による (3.) の HMM 各状態のセントロイドからの偏移クラスタリング.

(6) Performance correlation (fine)

DBN によるピアノの Style parameters と (5.) の偏移クラスタとのマッチング学習.

図 3 に Training phase の学習プロセスの概要を示す.

4.1.1 Stacked bidirectional LSTM

LSTM は時系列データに対する DNN として広く用いられており [11], 我々のシステムでは, ピアノの Style parameters と HMM によってセグメント化されたベース及びドラムスの特微量空間における部分空間に対応するクラスタとのマッチングのためのネットワークとして適用している (図 3 の赤矢印).

図 4 に本システムにおける LSTM のネットワーク構造を示す. 通常の LSTM では時系列順に入力系列に対する出力系列を学習するが, 本システムで採用した LSTM は前向きと後ろ向きの LSTM ネットワークを結合する bidirectional




図 5 DBN ではピアノの演奏特微量ベクトルと HMM によって得られた各状態からの偏移ベクトルとのマッチングを学習する.




図 6 ジャズセッションにおける即興演奏の生成過程.

なユニットを多段に重ねた構造をもつことで, 前向きの時系列順だけでなく系列全体のコンテキストを反映した学習が可能となる. 本システムでは bidirectional ユニットを 3 層重ねた構造を採用した [12].

4.1.2 Deep berief network

DBN は Restricted Boltzmann Machine (RBM) [13], [14], [15] によってプリトレーニングされた重みを初期値として多層のニューラルネットを学習するネットワークで, 代表的な DNN として広く用いられている. 本システムでは RBM を 5 層に重ね, ピアノの Style parameters とベース及びドラムスの HMM によって得られた各状態からの偏移クラスタとのマッチングのための学習を行った (偏移クラスタは図 3 の太緑矢印, DBN ネットワークは同図の青矢印).

また, 図 5 に本システムにおける DBN の入出力関係とネットワークを示す.

4.2 Synthesizing phase: ベース及びドラムスの演奏生成

Synthesizing phase では, 前節に述べたニューラルネットを用いて, 入力ピアノ演奏特微量からベース及びドラムスの演奏状態を推定し, その状態に基づいた演奏の生成を行う.

一般にジャズ演奏家によるセッションのインプロビゼーションは, 以下の 3 ステップによって行われる (図 6).

(1) 調性とコードから, 利用可能なスケール (Available note scale: ANS) を推定し, 音高パターンを設計.

(2) 現在の演奏状態に適したリズムパターンを選択 (生成).

(3) 音高パタンとリズムパタンを合成.

ドラムスの場合は音高情報がないため (スネアドラムやハイハットも含めて1つの楽器によるリズムパタンと見なせる), (2.)が重要となる. 従って, 計算機においても同様の手順により自動生成を実現する.

4.2.1 ベースの音高パタン生成

一般にベースは大きな跳躍進行をすることは少なく, 一つ前の音, あるいはその小節内における平均的なベースの音高から外れた音は演奏されづらい. 従って, 学習データから得られた音高レンジの分散を用いたガウス分布を用いることで, 確率的な音高パタンの生成が可能である. HMMの状態 S と GMM による偏移クラスター C におけるベースの音高レンジ標準偏差を $\sigma_{S,C}$ とすると, 音高パタン (メロディ) 生成プロセスにおいて, ある小節 t における i 番目の MIDI ノートナンバー $x_{t,i}$ は,

$$x_{t,i} \sim \mathcal{N}\left(\frac{1}{N_{t,i-1}} \sum_{j=0}^{i-1} x_{t,j}, \frac{\sigma_{S,C}}{2}\right), \quad (8)$$

で与えられる. $N_{t,i-1}$ は t 番目の小節における $i-1$ 番目のノートまでのノート数を表す. すなわち, $i-1$ 番目までの音高平均を分布平均とし, 状態 S 及び偏移 C における音高レンジを2で割ったものを標準偏差として分散に適用したガウス分布から確率的に生成される.

4.2.2 リズムパタン生成

伴奏楽器のリズムパタンの生成においては, リズム木仮説を採用した [16]. リズム木仮説ではルートノードとして全音符を仮定し, 確率的に二分音符や休符, さらに四分音符や八分音符などにリズムパタンが次々と分割されて生成されるモデルである. 本システムではリズム木の生成について最尤推定に基づく確率計算と, Probabilistic Context Free Grammar (PCFG) に基づいた手法の2種類について検討した. 最尤推定手法については, 全音符から2つの二分音符, 二分音符と二分休符, 二分休符と二分音符のいずれかに分枝される. いずれかの区間にノートオンの情報があつた場合は, これをさらに四分音符単位で分割し, 最終的に十六分音符を最小分割単位とした分枝確率を最尤推定によって求める. 一方, PCFG によるモデルの推定は HMM と同様に補助関数法 (EM アルゴリズム) によって定式化でき, HMM における Baum-Welch アルゴリズムと似た Inside-outside アルゴリズムによって, 少ない計算量で推定可能である. PCFG ではリズム分割のための文法を明示的に与えることで, よりバラエティに富んだリズム構造を与えることができるが, 本研究では拡張可能性を念頭に上記の分枝と同等のモデルによる実装を行った.

最尤推定と同様のルールを与えるならば, ルートノードを R, ノートオンを O, 休符を F とし, 二分音符を O2, 四分音符を O4 のように表すと,

表 1 Parameters

HMM parameters	
The number of state	4
The number of mixture	4
Epoch	100
GMM parameters (deviation from center)	
The number of mixture	8
Epoch	200
LSTM parameters	
Learning rate	0.0001
The number of layers	3
The number of middle layer units	30
Momentum	0.9
Drop out	0.5
Epoch	5000
DBN parameters	
Learning rate	0.00001
The number of hidden units (RBM)	50
Momentum	0.9
Weight decay	0.001
Objective average activation	0.01
Coefficient for sparse regularization	0.1
The number of layers	5
Prior epoch	10000
Epoch	100000

- R → O2, O2
 - R → O2, F2
 - R → F2, O2
 - R → F2, F2
 - O2 → O4, O4
 - O2 → O4, F4
 - O2 → F4, O4
 - F2 → F4, F4
 - O4 → O8, O8
 - O4 → O8, F8
 - O4 → F8, O8
 - F4 → F8, F8
 - O8 → O16, O16
 - O8 → O16, F16
 - O8 → F16, O16
 - F8 → F16, F16
- のように書ける.

5. 実験

12 曲のジャズピアノトリオ曲を用いて学習し, 学習に用いなかった曲 ('Autumn Leaves') のピアノのみのパートを用いて自動生成を行った. 実装は Python をベースに, Stacked bidirectional LSTM は機械学習ライブラリの Chainer を利用し, DBN は数値計算用ライブラリ Theano を用いた. 実装に用いたパラメータを表 1 に示す.

実際に LSTM による学習と Stacked bidirectional LSTM による学習を行い、演奏状態の推定精度を比較したところ、LSTM による演奏状態推定精度のエラーレートは、ベースが 26%、ドラムスが 49% であったのに対し、Stacked bidirectional LSTM によるエラーレートは、ベースが 19%、ドラムスが 36% と精度の向上が見られた。一方、予備的に 2 名の実験協力者に最尤推定によるリズム木と PCFG によるリズム木による生成楽曲の比較聴取実験も行ったが、いずれも同等の評価しか得られなかった。これは状態推定精度の向上が見られた一方で、曲全体としては(これまでも一部不適な演奏箇所もあったこともあり)明確な差異が認められなかったこと、また生成されたリズムパターン(構造)にも大きな変化が見られなかったことが理由として挙げられる。

6. おわりに

我々は統計的に学習可能な枠組みにおけるジャズセッション実現のための数理モデルを提案し、その妥当性実証のためにオフラインシステムにより生成した楽曲による比較実験を行った、その結果として、stacked bidirectional 構造を適用したことによる推定精度の向上は見られたが、生成した曲に対する有意な評価は得られなかった。しかしこれはリズム文法の充実化による改善や拡張性が期待できることも示唆しており、今後の取り組むべき課題の 1 つである。

また、オンラインシステムとしての実装や音響入力への対応なども今後視野に入れた研究を行う。

参考文献

- [1] Takeda, H., T, N., Sagayama, S. et al.: Automatic accompaniment system of MIDI performance using HMM-based score following, *IPSJ SIG Technical Reports*, pp. 109–116 (2006).
- [2] Nakamura, E., Takeda, H., Yamamoto, R., Saito, Y., Sako, S., Sagayama, S. et al.: Score Following Handling Performances with Arbitrary Repeats and Skips and Automatic Accompaniment, *IPSJ Journal*, Vol. 54, No. 4, pp. 1338–1349 (2013).
- [3] Hori, T., Nakamura, K. and Sagayama, S.: Automatic selection and concatenation system for jazz piano trio using case data, *Proc. ISICIE International Symposium on Stochastic Systems Theory and its Applications*, Vol. 2017 (2017).
- [4] 保利武志, 中村和幸, 嵯峨山茂樹: HMM に基づくジャズセッションシステムにおけるベース・ドラムスの演奏に関する検討, 情報処理学会第 79 回全国大会講演論文集, Vol. 2017, No. 2, pp. 129–130 (2017).
- [5] Hori, T., Nakamura, K. and Sagayama, S.: Jazz Piano Trio Synthesizing System Based on HMM and DNN, *Proc. 14th SMC*, Vol. 2017, pp. 153–158 (2017).
- [6] Wake, S., Kato, H., Saiwaki, N. and Inokuchi, S.: Cooperative Musical Partner System Using Tension - Parameter : JASPER (Jam Session Partner), *IPSJ Journal*, Vol. 35, No. 7, pp. 1469–1481 (1994).
- [7] Hidaka, I., Goto, M. and Muraoka, Y.: An Automatic Jazz Accompaniment System Reacting to Solo, *IPSJ SIG Technical Reports*, Vol. 1995, No. 19, pp. 7–12 (1995).
- [8] Goto, M., Hidaka, I., Matsumoto, H., Kuroda, Y. and Muraoka, Y.: A Jazz Session System for Interplay among All Players I. System Overview and Implementation on Distributed Computing Environment, *IPSJ SIG Technical Reports*, Vol. 1996, No. 19, pp. 21–28 (1996).
- [9] Hidaka, I., Goto, M. and Muraoka, Y.: A Jazz Session System for Interplay among All Players II. Implementation of a Bassist and a Drummer, *IPSJ SIG Technical Reports*, Vol. 1996, No. 19, pp. 29–36 (1996).
- [10] Hamanaka, M., Goto, M., Aso, H. and Otsu, N.: Guitarist Simulator: A Jam Session System Statistically Learning Player's Reactions, *IPSJ Journal*, Vol. 45, No. 3, pp. 698–709 (2004).
- [11] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, *Neural computation*, Vol. 9, No. 8, pp. 1735–1780 (1997).
- [12] Graves, A. and Schmidhuber, J.: Framewise phoneme classification with bidirectional LSTM and other neural network architectures, *Neural Networks*, Vol. 18, No. 5, pp. 602–610 (2005).
- [13] Hinton, G. E., Osindero, S. and Teh, Y. W.: A fast learning algorithm for deep belief nets, *Neural computation*, Vol. 18, No. 7, pp. 1527–1554 (2006).
- [14] Freund, Y. and Haussler, D.: Unsupervised learning of distributions on binary vectors using two layer networks, *Advances in neural information processing systems*, pp. 912–919 (1992).
- [15] Hinton, G. E.: Training products of experts by minimizing contrastive divergence, *Neural computation*, Vol. 14, No. 8, pp. 1771–1800 (2002).
- [16] Tsuchiya, M., Ochiai, K., Kameoka, H. and Sagayama, S.: Probabilistic model of two-dimensional rhythm tree structure representation for automatic transcription of polyphonic MIDI signals, *Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2013 Asia-Pacific*, IEEE, pp. 1–6 (2013).