

音響信号と音楽的制約を統合した バイオリンの演奏弦系列の推定

前 澤 陽^{†1} 糸 山 克 寿 高 橋 徹
尾 形 哲 也 奥 乃 博

本報告ではコンテキストベースの規則と音響信号を併用したバイオリン演奏弦系列推定手法を提案する。音響信号から演奏弦系列を推定し、その規則に合わない箇所を訂正することにより認識率の向上を図る。6 楽節での実験の結果、学習データと同一の弦の場合最大 8%、平均 5%、別の銘柄の弦の場合最大 15%、平均 7%の認識率の向上が確認される。

Estimation of Bowed String Sequence of a Violin Performance Using Audio and Score-Based Anomaly Detection

AKIRA MAEZAWA^{†1}, KATSUTOSHI ITOYAMA,
TORU TAKAHASHI, TETSUYA OGATA
and HIROSHI G. OKUNO

We present a violin bowed string sequence identification method by combining context-based rules and audio-based bowed string estimator. Using audio-based estimator followed by error correction using context-based rules increases the accuracy of the estimator. Using six musical phrases, we confirm that the accuracy increases on average by 5% (max. 8%) when using the set of strings used for training, and, when using different brand of strings than that used for training, confirm 7% increase on average (max. 15%).

^{†1} 京都大学大学院情報学研究科 知能情報学専攻
Department of Intelligence Science and Technology
Graduate School of Informatics, Kyoto University

1. はじめに

音楽家同士がお互いを探す場所としてのオンラインコミュニティの重要性は近年増してきている。一例として、ネットを通じたやりとりのみでアマチュアオーケストラを形成した YouTube Symphony Orchestra (以下 YTSO) が挙げられる [1]。YTSO では参加希望者がデモ録音を公開し、それをコミュニティが評価することにより適切なメンバーが選ばれた。しかし、参加希望者がコミュニティの評価能力を大幅に越えることのようなデモ録音の全数を評価することは不可能となる。特にバイオリンは、オーケストラでは最もよく使われる楽器の一つであり、演奏者人口も多いため、上記の問題が発生しやすい。そこで、演奏者のコミュニティに対する適性をデモ録音から自動評価した上で、適性が高い演奏者のみをコミュニティで評価することが必要となる。

演奏者の適性を評価する際には技術力と音楽性の両者を考慮する必要がある。バイオリンの演奏はだまかに分けて運指と弓使いの二つの側面を持つ。演奏解析のために弓使いを検出する技術 [2-4] は広く研究されてきたが、運指に関するそれは少ない。しかし、音楽表現と技術力に関する運指重要性については広く知られている [5-7]。例えば、技巧的な楽節では弾きやすい運指を選び、「歌うような楽節」(カンティレーナ) では仮に弾き辛くても適切な音色が出せる弦を選ぶことがよいとされている [7]。演奏者の技術力の限界と楽曲の解釈によって実際の運指は定まるため、運指推定により演奏者の運指に関する技術と音楽性について知ることができる。

バイオリンの運指にまつわる問題は大きく二分され、それぞれ個別に扱われてきた。一つは、楽譜を与えられたときにその楽譜に対して適切な運指を決定する問題で、楽譜というコンテキストに依存するコストの最小化問題として扱われる [8, 9]。もう一つは、与えられた音響信号のみから、演奏された弦を推定する問題である [10]。演奏者の技術と音楽性を評価するという観点からは後者のアプローチが主となるが、前者の問題で扱われていたような楽譜というコンテキストに依存する制約条件を導入することで、弦の推定精度の向上が期待される。

本報告では、コンテキストに基づく制約条件を用いて音響信号から演奏弦系列を推定する手法を提案しその評価を行う。本手法では音響信号から推定された演奏弦系列が楽譜から導かれた経験則に則っているかを判断し、経験則に従わない弦系列があればその部分に修正を施すことにより、より「常識的」な演奏弦系列を推定する。2 章で手法の説明をし、3 章でコンテキスト併用の評価実験を行い、4 章、5 章で結果の考察を行う。

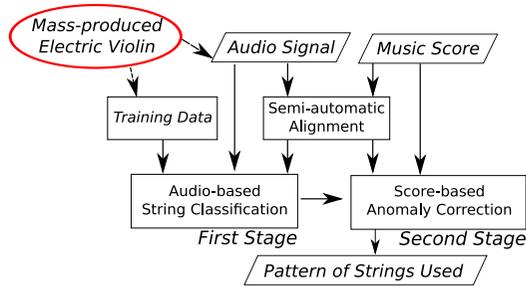


図1 システム構成
Fig.1 System-Level Diagram

2. 手 法

本手法は図1に記すように二段階の構成からなる。まず音響信号を基に演奏弦の系列を推定し、コンテキストベースのルールを満たさない検出結果をエラーのとみなし、可能ならば修正を施す。

2.1 バイオリンの弦について

バイオリンは四本の弦から構成され、隣接する弦は完全五度の音程で調弦されている。図2に記されているように、それぞれ G (5500cent), D (6200cent), A (6900 cent), そして E (7600 cent) と調弦されている。各弦はおよそ 2.5 オクターブの演奏可能な音域を持ち、それぞれが異なる音色を持つ。基本的に各弦の高域に行けば行くほど引き辛くなるため、初心者ほど低域を好んで弾く傾向がある。

音程は弦の上を指で押さえることにより決定される。一本の弦が演奏可能な音域が隣接する弦の音程より遙に広いため、楽節が与えられた時の演奏弦系列は一意とは限らない。

2.2 コンテキストに基づく規則とそれに基づいたエラー検出と修正

音響信号を用い推定された演奏弦系列から楽節のコンテキストから離れた推定結果をエラーとみなし修正することにより認識率の向上が図られることが予測される。バイオリンの運指を観察することにより我々は以下の経験則を導入する：

二音の系列において、いずれも解放弦で弾けられない場合、

- (1) 二音目が一音目よりも高ければ演奏弦は低い弦に移行しない
- (2) 二音目が一音目よりも低ければ演奏弦は高い弦に移行しない

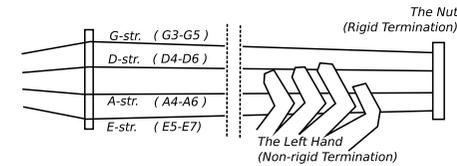


図2 バイオリン運指に関する用語
Fig.2 Terminologies Pertaining to the Violin Strings

これらに沿わない結果をエラーと定義する。

エラー見つけ修正するアルゴリズムを Algorithm 1 に示す。ここで、 $S = \{S_1 \dots S_N\}$ とは単音の N 音から構成される楽譜で、 S_i は i 番目の音符を MIDI ノートナンバーで表している。 $St = \{St_1 \dots St_N\}$ は演奏弦の系列であり、 St_i は i 番目の演奏弦に対応する。経験則を再帰的に考えると、音程が下がる楽節では演奏弦は高い弦に移行しないと考えることができる。そこでそのようなフレーズを $OP = \{>, <\}$ とし、 OP に従う連続した楽節を抽出する。続いてここで抽出された楽節を Algorithm 2 を用いエラーを検出し訂正する。

Algorithm 1 経験則に基づくエラー検出/訂正アルゴリズム

```

procedure error-correction( S, St )
for all OP = {>, <} do
   $i_b := 1$  {  $i_b$  = 解析開始位置 }
   $i_e := 1$  {  $i_e$  = 解析終了位置 }
  repeat
    while  $i_e < |S| \wedge (S_{i_e} \text{ OP } S_{i_e+1})$  do
       $i_e := i_e + 1$ 
    end while
    if  $i_b \neq i_e$  then
       $St := \text{remove-error}( i_b, i_e, S, St, OP )$ 
    end if
     $i_b := i_e + 1$ 
  until  $i_b > |S|$ 
end for
  
```

Algorithm 2 エラー検出/訂正

```

procedure remove-error(  $i_b, i_e, S, St, OP$  )
  Errors :=  $\{j \in [i_b + 1, i_e] | \neg(St_{j-1} OP St_j)\}$ 
  for all  $i \in$  Errors do
    for all  $(u, v) = \{(i, i - 1), (i - 1, i)\}$  do
      if  $\neg$  ( $S_u$  と  $St_u$  は解放弦でしか演奏できない) then
        temp :=  $St_u$ 
         $St_u := St_v$ 
         $a_{new} := \{j \in [i_b + 1, i_e] | \neg(St_{j-1} OP St_j)\}$ 
        if  $|a_{new}| = |Errors|$  then
           $St_u := temp$ 
        else
          break
        end if
      end if
    end for
  end for
  return St

```

2.3 音響信号を用いた演奏弦系列の推定

演奏弦系列の推定には混合音からの基本周波数 (F0) 抽出, 音響特徴量からの弦識別と音符単位のセグメンテーションが必要である。今回は単音の楽節を扱うが, バイオリンでは単音の楽節を弾いたとしても前の音の弦の減衰が特に解放弦においては残ることがあり一般に複数の音が同時になっている。上記の理由により F0 抽出と特徴量は混合音に対しロバストである必要がある。

F0 を抽出した後は, 前項で説明した誤検出を見つけるためにそれを音符単位でセグメント化する必要がある。

2.4 F0 抽出

使用される音響特徴量が F0 に大きく依存するため, F0 の推定精度は 10 cent オーダーで取るのが望ましい。しかし, 混合音にロバストな F0 推定アルゴリズムは推定精度を向上さ

せると計算時間が増大する傾向がある。そこで, 本手法では混合音にロバストな F0 推定手法で大雑把に F0 を推定し, そこから計算時間が軽いアルゴリズムを用いて詳細な F0 を推定する。

ここで, 混合音にロバストな F0 推定アルゴリズムとして PreFEst を採用する [11]。解像度を 50 cent, フレーム長を 2048 サンプル, サンプリング周波数を 44.1kHz, 音モデルは擦弦楽器の弦が作り出す波形が鋸状であることを利用し鋸波とする [12, 13]。

PreFEst を用い F0 を大雑把に推定してから自己相関関数 (ACF) を用いた F0 抽出を行う [14]。ここでは入力信号をゼロ詰めし長さ 16384 の FFT の自己相関を求め, PreFEst で推定された F0 の周囲 50 cent のピークを以下に記すように探索する。

$$c_{0,ACF} = b2c(\arg \max_{k \in [c2b(c_0 - \Delta c), c2b(c_0 + \Delta c)]} X(k)X^*(k)) \quad (1)$$

ただし, c_0 は PreFEst によって推定された F0 を cent で表したものの, $\Delta c = 50cent$, $X(k)$ はゼロ詰めされた信号の FFT, $b2c$ は周波数を bin から cent に変換し, $c2b$ はその逆関数とする。

2.4.1 無音区間の検出

楽器が鳴っていない箇所は解析する必要がないため無音区間をスキップする必要がある。そこで, ゼロ交差比率 (ZXR) に基づく無音区間の検出を行う [15]。ここでは時系列の信号 $x(n)$ が与えられたときに以下を計算することにより ZXR を求める。

$$Q = ZXR_N \left(x(n) - \sum_{k=1}^N x(k)/N + \delta \right) \quad (2)$$

ここで, $\delta_j = 1e-4$ はバイアス, ZXR_N が長さ N のフレーム内での信号の符号が変化した数とする。無音ではない音は $Q > 2N \frac{150.0}{f_s}$ を満たすものとして定義する (ただし f_s はサンプリング周波数で N はフレーム長)。

2.4.2 半自動ノートセグメンテーション

音響信号と楽譜との対応付けは半自動的に行われる。まず各音符に対し手動でその音に対応付けられるフレーム一つが関連付けられる。この関連付けが終わると本手法では音の境界を F0 の軌跡と無音区間をみることにより行う。音の境界とは (1)F0 の軌跡が楽譜の音程よりも 50 cent 以上ずれる, (2) 無音区間に接する, 又は (3) 隣接する音符の境界に触れる, いずれかの条件を満たすものと定義する。

2.4.3 特徴量抽出

音響特徴量として 80Hz から 15kHz に中心周波数を持つ対数周波数軸上に等間隔に配置された 14 個の三角フィルタの出力エネルギーのうち中心周波数が高い 8 個を選ぶ。エネルギー

ギーはフィルタバンクの総出力エネルギーをノーマライズしたのち dB として表現する。バンド幅は対数軸上で等幅になるように設定されカットオフ周波数は隣接するフィルタの中心周波数になるように設定されている。

混合音に対しロバストであるために、上述の特徴量は F0 とナイキスト周波数までの F0 の整数倍に含まれるエネルギーのみに対して行われる - すなわち調波構造のみを考慮する。この計算はゼロ詰めされたパワースペクトルに対して行う。

2.4.4 特徴量の F0 依存モデル

特徴量は F0 に依存するパラメータを持つ混合ガウス分布 (GMM) としてモデルする。これを行うため、まず入力データを F0 に基づきクラスタリングする。クラスタセントロイドは周波数軸上に等間隔に 25cent の幅で配置されている。すなわち、セントロイド \hat{c} を以下のように配置する

$$\hat{c} = \{\hat{c}_k | 1 \leq k \leq k_{max}, \hat{c}_k = c_{min} + k\Delta c\} \quad (3)$$

そして入力データが F0 と音響特徴量のペア (c_0^i, x^i) として以下のように与えられているとする：

$$\{(c_0^{(0)}, x^{(0)}), \dots, (c_0^{(M)}, x^{(M)})\} \quad (4)$$

すると i 番目のデータ $(c_0^{(i)}, x^{(i)})$ を k_{max} クラスのうちの下記の条件が成立するクラス $k^{(i)}$ に割り当てられる。

$$k^{(i)} = \arg \min_k |\hat{c}_k - c_0^{(i)}| \quad (5)$$

このようにしてクラスタリングしたデータを用い、各クラスに対して個別の混合数 5 の GMM を各弦に対して学習させる。 \mathbf{X}_k をその列に k 番目のクラスに割り当てられたデータが含まれているデータ行列とする。ここで k 番目のクラスにアサインされたデータ x を以下のように表す。

$$x = \text{ave}(\mathbf{X}_k) + \mathbf{e}_k \quad (6)$$

$$\text{ave}(\mathbf{X}_k) = \left(\sum_{i=1}^L \text{row}(X_k, i) \right) / \text{length}(C_k) \quad (7)$$

ここで $\text{row}(X, i)$ は X の i 番目の列を抽出し、 $\text{length}(v)$ はベクトル v の要素数を返し、 \mathbf{e}_k がクラス k のエラーである。この様にモデルされたデータに対し、演奏弦クラスの差異を e_k を GMM として各クラスに対して学習させる。すなわち、クラス c のエラー $\mathbf{e}_k(c)$ を以

下のように表す。

$$p(\mathbf{e}_k | c) = \sum_{j=1}^5 \phi_j(c) N(\mathbf{e}_k | \mu_j(c), \Sigma_j(c)) \quad \text{s.t.} \quad \sum_{j=1}^5 \phi_j(c) = 1 \quad (8)$$

これらを組み合わせ特徴 x をクラス c と F0, c_0 , が与えられた時に観察する尤度を以下のように表す：

$$p(x | c_0, c) = \sum_{l=1}^5 \phi_l(c) N(x - \text{ave}(\mathbf{X}_k) | \mu_l(c), \Sigma_l(c)) \quad (9)$$

2.4.5 識別規則

以上のように弦のクラスのモデル化を行い、未知の楽節に対し演奏弦系列の推定を行う。各音符に対し、演奏弦はそれに含まれるすべてのフレームの弦の最尤推定結果の多数決によって求められる。すなわち、 n 番目の音符 N_n がフレーム $b(n)$ から $e(n)$ の間に演奏されているとし、その間の F0 とデータ系列を以下のように表す。

$$N_n = \{(c_0^{(b(n))}, x^{(b(n))}), \dots, (c_0^{(e(n))}, x^{(e(n))})\} \quad (10)$$

この音符が弾かれた弦を下記のようにして求める。

$$S_n = \arg \max_{m \in \{E, A, D, G\}} |\text{count}(m)| \quad (11)$$

$$\text{count}(m) = \{j \in [b(n), e(n)] | \arg \max_l p(x^{(j)} | c_0^{(j)}, l) = m\} \quad (12)$$

3. 実験

評価データは Yamaha Silent Violin SV150 が用いられた。訓練データとして各弦に対しその弦の解放弦から始まる 2 オクターブの半音音階を 3 回収録した。各音に対し音色を変える要因である弓速、弓圧と弓から駒への距離を連続的に変化させるようにしデータが収録された。

評価として 2 種類の弦の銘柄 (訓練データと同一の弦と別の銘柄) で収録された表 1 に記す楽節 3 節を二通りの運指で収録した。運指は弦の音色の一貫性を重視する運指 F1 と技術的に易しく初心者にも弾ける運指 F2 を選定した。F1 は弦の移行が少なく各弦の高音域に渡る運指が多く、F2 は弦の移行が多いが各弦の低い音域を多用する運指が多い。

4. 結果

ここで、音響信号からの特徴抽出における弦の銘柄の差異に対するロバスト性を認識率の差異で評価し、エラー訂正アルゴリズムの妥当性をアルゴリズム適用前後の認識率と、アルゴリズムが実際に検出できたエラーの割合と、正しい修正を施せた音符と検出されたエラーの

表 1 実験に使用された楽節
Table 1 Description of the Pieces Used

	曲名	音符数	開始節	終了節
Piece 1	Brahms Op.100 (第二楽章)	91	Bar 1	Bar 15
Piece 3	Mendelssohn Op.64 (第二楽章)	75	Bar 9	Bar 27
Piece 2	Brahms Op.100 (第三楽章)	41	Bar 1	Bar 12

表 2 適合率, 再現率, $F_{1/2}$ 値 (S=訓練データと同じ弦, D=違う弦の銘柄)
Table 2 Precision, Recall, and $F_{1/2}$ -measure
(S=The Set of Strings Used During Training, D=Different Set)

楽節/運指	Pr. (S)	Rc. (S)	$F_{1/2}$ (S)	Pr. (D)	Rc. (D)	$F_{1/2}$ (D)
P1F1	0.86	0.38	0.68	0.43	0.20	0.35
P1F2	0.50	0.04	0.15	0.71	0.16	0.42
P2F1	N/A	N/A	N/A	N/A	N/A	N/A
P2F2	1.00	0.27	0.65	1.0	0.21	0.58
P3F1	0.75	0.26	0.55	0.55	0.26	0.45
P3F2	1.00	0.18	0.53	0.40	0.06	0.19

総数の比率として評価する。後者の評価には適合率 (Pr.), 再現率 (Rc.) と $F_{1/2}$ 値 ($F_{1/2}$) を用いる。ここで, Pr. はエラーと認識された音符のうち正しい修正が施されたものの割合, Rc. は正しい修正が施された音符数と音符の総数の割合, そして $F_{1/2}$ は下記のように定義される:

$$F_{\beta} = ((1 + \beta^2)PrRc) / (\beta^2Pr + Rc) |_{\beta=1/2} \quad (13)$$

モデルを習得するために使われた弦の銘柄と他の銘柄の弦を使用したときの認識率をそれぞれ図 3 と図 4 に示す。同時に, エラー訂正アルゴリズムを適用前後の認識率の向上を各図に記している。続いて, 表 2 にアルゴリズムの適合率, 再現率, と $F_{1/2}$ 値を示す。

演奏弦推定精度の Confusion Matrix をエラー訂正アルゴリズム適用前後で比較したものを, 訓練データに使われた弦とそうでない弦についてそれぞれ表 3 と表 4 に記す。

5. 考察

図 3 と図 4 のアルゴリズム適用前の正解率を比較すると, 弦が変わると正解率が低下することが確認される。

表 3 と表 4 は多くの誤認識が正解の弦よりも低い弦と誤認識される。P2F1 は一番低い弦のみで奏でられるため, 認識率が他と比べ圧倒的に高い物と思われる。

表 3 Confusion Matrix (訓練データと同一の弦)
記法: 「アルゴリズム適用前 → 後 [音符数]」

Table 3 Confusion Matrix (Strings Used for Training,
Notation: Num. of Notes Before Applying the Algorithm →After)

正解 \ 実際	G	D	A	E
G	71→71	0→0	0→0	0→0
D	17→11	50→55	1→2	0→0
A	14→8	35→30	157→168	6→3
E	0→0	4→2	23→21	41→45

表 4 Confusion Matrix (訓練データと別の弦)
記法: 「アルゴリズム適用前 → 後 [音符数]」

Table 4 Confusion Matrix (Diff. Strings From Those Used for Training,
Notation: Num. of Notes Before Applying the Algorithm →After)

正解 \ 実際	G	D	A	E
G	71→71	0→0	0→0	0→0
D	35→27	32→39	1→2	0→0
A	64→40	46→40	93→113	6→16
E	3→1	3→1	11→11	51→55

平均的に, モデルを習得するのに使われた弦では訂正アルゴリズム適用前の認識率は 78%, 適用後 83%, 別の銘柄では適用前 63%, 適用後 70%となっている。このことから弦の銘柄に関係なく, 音響信号のみを使った場合と比べ, エラー訂正アルゴリズムを採用することによりおよそ 6%の認識率の向上が見込める。

本訂正アルゴリズムでは本質的に複数のエラー訂正方法が存在する, 曖昧性のあるエラーが存在する。例えば, 図 5 のような場合に検出されたエラーの修正は一意に求まるのに対し, 図 6 のようなエラーの場合, その修正は一意には求まらない。これが適合率の低さの一部の理由だと思われる。

一般的に低い再現率はアルゴリズムが検出できないエラーが多く存在することを意味する。これは音響信号に基づく演奏弦系列の質が低いいためか, 弦の差異による音色の変化が本質的に検出しづらいものであることを意味する。いずれにせよ, これは更なる音響信号に基づく演奏弦系列の推定精度の向上が必要であることを示唆する。

6. 結論

本報告では, コンテキストに基づく規則を用いた演奏弦系列のエラー訂正と音響信号に基

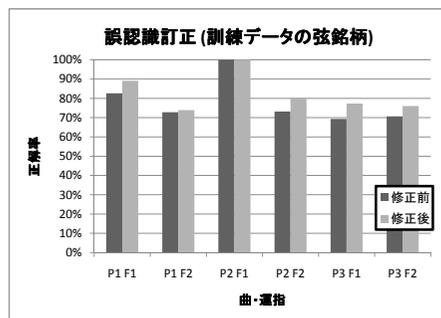


図 3 訓練データと同一の弦を使用したときの認識率
Fig.3 Accuracy when Using Strings Used for Training

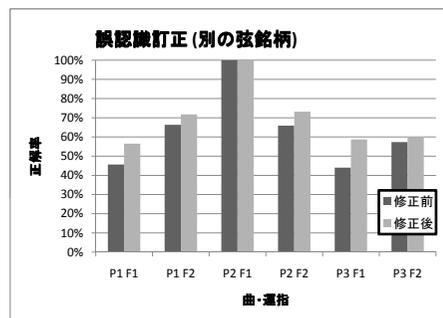


図 4 訓練データとは別の銘柄の弦を使用したときの認識率
Fig.4 Accuracy when Using Different Brand of Strings

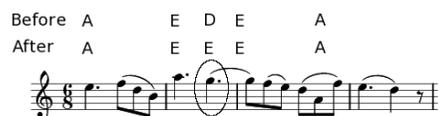


図 5 曖昧でないエラーとその訂正
Fig.5 An Example of the Unambiguous Error



図 6 曖昧であるエラーとその訂正
Fig.6 An Example of the Ambiguous Error

参考文献

- 1) YouTube Symphony Orchestra. <http://www.youtube.com/symphony/> (as of 2 Apr. 2009).
- 2) C. Peiper, D. Warden, G. Garnett: An Interface for Real-time Classification of Articulations Produced by Violin Bowing. *Proc. of the 2003 Conf. on New Instruments for Musical Expression (NIME-03)*, 192–196
- 3) I. Barbancho, C. Bandera, A. M. Barbancho, L. J. Tarzon: Transcription and Expressiveness Detection System for Violin Music. *Proc. of the IEEE Int'l Conf. on Acoustics, Speech and Signal Processing (ICASSP)*, 189–192, 2009.
- 4) D. Young: The Hyperbow Controller: Real-Time Dynamics Measurement of Violin Performance. *Proc. of the 2002 Conf. on New Instruments for Musical Expression (NIME-02)*, 65–70, 2002.
- 5) R. Stowell: Technique and Performing Practice. In R. Stowell (Ed.), *The Cambridge Companion to the Violin*, Cambridge University Press, Cambridge, 1992.
- 6) C. Flesch: *The Art of Violin Playing, Book One*, Carl Fischer, L.L.C., New York, 2000.
- 7) I. M. Yampolsky: *Principles of Violin Fingering*, Oxford University Press, Oxford, 1967.
- 8) D. Radicioni, L. Ansemala, and V. Lombardo: A Segmentation-based Prototype to Compute String Instruments Fingering. *Proc. of the First Conference on Interdisciplinary Musicology (CIM04)*, Graz/Austria, Apr. 2004.
- 9) S. Sayegh: Fingering for String Instruments with the Optimum Path Paradigm. *Computer Music Journal*, Vol. 13, No. 3, Fall 1989, MIT.
- 10) A. Krishnaswamy, J. Smith: Inferring Control Inputs to an Acoustic Violin From Audio Spectra. *Proc. of the 2003 Int'l. Conf. on Multimedia and Expo*, Vol 2., 733–736, 2003.
- 11) M. Goto: A Real-time Music Scene Description System: Predominant-F0 Estimation for Detecting Melody and Bass Lines in Real-world Audio Signals. *Speech Communication*, Vol.43, No.4, pp.311-329, Sept. 2004.
- 12) L. Cremer: *The Physics of the Violin*, MIT Press, 1984.
- 13) N. Fletcher, T. Rossing: *The Physics of Musical Instruments*, Springer, 1998.
- 14) J. Dubnowski, R. Schafer, L. Rabiner: Real-time Digital Hardware Pitch Detector. *IEEE Trans. on Acoustics, Speech, and Signal Processing*, Vol. 24, No. 1, pp.2-8, Feb. 1976.
- 15) L. Rabiner, and B. H. Juang: *Fundamentals of Speech Recognition*, Prentice Hall, 1993.

づく演奏弦同定を併用したバイオリン演奏における演奏弦系列の推定手法を提案し、エラー訂正の有効性を示した。特に、複数の銘柄の弦を使用したときに生じる音響特性の変化により音響信号に基づく演奏弦同定における正解率は低下するが、コンテキストに依存する制約条件を併用させることにより劣化を抑制できることが確認された。

今後は、演奏される弦の組み合わせの違いや個体差による音響特性の差異を吸収する適応手法の採用、音響特徴からの演奏弦同定精度の向上、運指計画問題でのコンテキストに基づく制約の知見との更なる統合を行っていく予定である。

7. おわりに

謝辞 本研究の一部は科学技術振興機構 CrestMuse プロジェクトによる支援を受けた。運指の決定の大部分はバイオリニスト Pattie Sunwoo と Peggy Klingner の教示に基づいた。