

# ラフ集合を用いたヴァイオリン演奏者の特徴抽出

## Feature Extraction of Violinists by Rough Sets

清水聡史<sup>\*1</sup>

Satoshi Shimizu

吉永早織<sup>\*1</sup>

Saori Yoshinaga

古川康一<sup>\*2</sup>

Koichi Furukawa

<sup>\*1</sup> 慶應義塾大学環境情報学部

Keio University Faculty of Environmental Information

<sup>\*2</sup> 慶應義塾大学政策・メディア研究科

Keio University Graduate School of Media and Governance

To examine the validity of Rough Sets Theory in the field of physical tacit knowledge, we worked on feature extraction of violinists. We had five players, three experts and two intermediate players. They played a given song, and their movements were recorded using EMG and Stabilometer. When we applied the recorded data to the Rough Sets Theory and analyzed it, we were able to see differences in the data between player levels. Therefore, from the results, we concluded that the Rough Sets Theory is valid.

### 1. はじめに

身体知とは言語知と並んで人類が獲得した財の中でも重要なものであり、また誰もが無意識的にさえ身に付けられるものである。そして、特定分野において巨匠と呼ばれるような人たちが現れ、その巧みな動きに圧倒されることがある。音楽の世界においても、熟達者はヴィルトゥオーソと呼ばれ、神のごとく正確でスケールの大きい演奏をする。

しかしながら、なぜそれが素晴らしいか、あるいは巧いのか、といったことを、感覚的に感じ取ることはできても明確に記述することは難しい。またどのようにして、そういった高度なスキルを身につけることができたのかを当事者に説明してもらおうとしても、演奏者ごとに違う説明をされ、その中から科学的な再現性のある、体系だった答えを見出すことは困難である。それは、彼らが高度なスキルを暗黙的に獲得してきたということとともに、音楽の教育法が、経験主義的なものとしてなされたということに起因する。そして、指導者が変わるたびに指導法も変わってしまうことは、現在でさえ起こりうることである。我々は、この経験主義的な土台に対して、暗黙知のモデル化を行おうと考えている。それにより、従来の方法における各練習段階の位置づけが分かるようになり、課題の取り組み順序の最適解も分かるようになっていくと考えている。チェロ演奏のモデル化においては、[五十嵐 03]、[植野 05] などがあげられる。

本稿ではデータマイニング手法の一つであるラフ集合を用いたヴァイオリン演奏のスキル分析に取り組み、演奏者の特徴抽出が可能であるかを検討する。ラフ集合は分析前に事前のメタ情報を必要とせず、多くの属性の中からコアとなる属性を抽出することができる。対象とする群の中で、ある対象だけが持つ属性の最小集合を切り出せ、少ない属性によって、専門家の多くの知識を説明することが可能である。我々は演奏家の動作を計測したデータから得られた特徴を属性値として解釈し、それらをラフ集合とみなすことによって各被験者間で異なる特徴を抽出できると考えた。具体的には、再解釈された各被験者の差、主にスキル中上級者の違いをラフ集合により解釈することによって、スキルサイエンス研究におけるラフ集合の有効性を検証していく。

### 2. ラフ集合とは

ラフ集合は 1982 年に提唱された理論で、日本では 90 年代の後半になって、感性工学の分野で用いられてきた。我々が何か対象を識別しようとするとき、大抵はある特徴的な属性を頼りに類別を行う。詳細に立ち入れれば対象を精密に記述できるが、核になる部分は何であるかが分かりづらくなり、一方、荒い掴み方では対象を十分に同定できないということが言える。これらを踏まえた適切なレベルの情報を取り出すことがラフ集合では可能である[Duntsch 00]。以下、ラフ集合の理論を、情報システム、決定表、決定ルール、決定ルールの評価、縮約の順に概説する。

#### 2.1 情報システム

ラフ集合は  $S = \langle U, \mathcal{A}, V, q, f, g \rangle$  の 4 要素によって構成される。これを情報システムと呼ぶ。U は対象集合、 $\mathcal{A}$  は属性集合、Vq は  $\exists q \in Q$  における属性値の定義域、fq は U とより属性値を設定する関数である。

#### 2.2 決定表と決定ルール

情報システムにおいて、ルールを導くために目的変数となる決定属性を設ける。決定属性は  $\mathcal{A}$  の要素である。その属性値は、決定クラスと呼ばれ[森 04, pp.12]、それを明示した表は決定表と言われる。この表が示すものを決定ルールと呼ぶ。決定ルールを最も短い記述長に変換したものを極小決定ルールと呼ぶ[森 04 pp.173-177]。

#### 2.3 決定ルールの評価

決定ルールを評価する上で Covering Index (以下 C.I.) という考え方がある。これは決定属性が同一の対象集合の中で、求められた極小ルールがどのくらいの頻度で使われるかに注目したものである。

#### 2.4 縮約

決定表で与えられたすべてのデータ属性群に対して、対象を類別可能にする最小限の属性部分集合のことを指す。縮約された集合は複数存在する可能性もある。

### 3. 生体データの計測

ヴァイオリン演奏時の身体的特徴抽出実験として、我々は床反力計による重心動揺計測と、筋電計による{拇指球筋, 上腕

二頭筋遠位部, 上腕三頭筋遠位部, 三角筋前部, 三角筋後部, 脊柱起立筋右側部)の活動電位の計測を行い, メトロノームにてテンポを四分音符を 120 とした(Fig. 1). 被験者は音大生レベルの上級者 3 名, 中級者 2 名とし, 実験課題としてヴァイオリン演奏の基本的技術を含む楽曲を用いた.




Fig. 1 実験の様子

実験により得られるデータはそのままではラフ集合に適用できないため, 属性集合別に属性化する必要がある. 筋電位計測データは, 信号処理後, 動作と各筋肉のズレや順序関係, ピーク値等のタイミングなどにより波形の特徴を解釈した. そしてそれらの解釈を属性集合として定め, 各被験者の特徴を属性値化した. 重心動揺計測データは, 重心の動揺範囲を表す

実効値面積(重心動揺をサイン波のように考え, その実効値(root mean square)を半径とした円の面積), 重心総移動距離を計測時間で割った単位軌跡長, X, Y 軸での標準偏差の指標を属性集合の要素として用い, 算出された値を程度により属性化することにした.

#### 4. ラフ集合の決定表

第 2 節, 第 3 節で述べた方法で, 決定表の作成を行う.[フレッシュ 64]や[ガラミアン 74]を参考にしながら, 信号として得られたデータを属性値化した. 本節で採用する属性については次の通り.

[筋電計] A: 八分音符の一弓連続移弦スラーの移弦時, 拇指球筋がダウンボウの返しでピークがあるか, B: 二分音符の一弓連続移弦スラーの移弦時, 上腕二頭筋がアップボウの返しでピークがあるか, C: 一弓連続移弦スラーの移弦で全体的に速い動作になった場合, 筋肉の活動レベルが下がっているか, D: 二分音符と四分音符の一弓連続移弦スラーの時, アップボウの返し点で他の動作よりも大きなピークが発生する筋肉(D0: 拇指球筋と三角筋前, D1: 三角筋後, D2: 拇指球筋と三角筋前・後), E: 弓返し時のテヌートとソーティエ(跳ね弓)を比較して, ソーティエの方が三角筋後部の活動電位が高まっているか, F: E の時点でソーティエの方が上腕二頭筋の活動電位が高いか.

[床反力計] G: 繰り返しの移弦動作時, 実効値面積が大きい(演奏時に体のゆれが大きい)か, H: 移弦を伴う弓の返しの連続動作で, X 軸より Y 軸に対しての変動が大きい(か), I: 八分音符と 16 分音符の移弦を伴う弓の返しを比較すると, 実効値面積において前者が後者の 10 分の 1 以下であるか(十六分音符の方が体のブレが極端に少ない), J: 実効値面積と単位軌跡長を比べて単位長の割に面積が小さいか(よく小刻みにぶれるが大きな動きは少ない)

[決定クラス] Z: 上級者(1)か中級者(0)か.

Name	A	B	C	D	E	F	G	H	I	J	Z
Ajiro	A0	B1	C1	D2	E1	F1	G1	H1	I1	J0	1
Mori	A1	B1	C1	D0	E1	F0	G0	H0	I0	J0	1
Oda	A1	B1	C0	D1	E1	F1	G0	H0	I0	J1	1
Imai	A0	B1	C1	D1	E1	F0	G1	H1	I1	J1	0
Shimizu	A1	B1	C1	D2	E0	F1	G0	H1	I1	J1	0

Fig. 2 決定表

#### 縮約した結果

[A, D][D, G][C, J][H, J][I, J]のような組み合わせが得られた. これらの集合のいずれかを用いることで, 対象となる群をすべて表現することができる.

#### 決定ルールの導出

Z=0(中級者)の時, C.I.値=1.0 となる極小決定ルールは [H2,J2], [I2,J2], [C2,J2] の組み合わせとなった.

Z=1(上級者)の時, C.I.値=0.666 となる極小決定ルールは [J1],[H1],[I1],[E2,G1],[E2,F2],[A2,E2]の組み合わせとなった.

#### 決定ルールの解釈

C.I.値=1.0 として最も強いルールが導かれた中級者の極小決定ルールには, J2 の「よく小刻みにぶれるが大きな動きは少ない」という条件が必ず組み込まれている. また, その他に「Y 軸方向に大きく揺れる」, 「八分音符よりも十六分音符の方が体のブレが極端に少ない」, 「ゆっくりとした音符を弾く動作時よりも八分音符などの早い動作時のほうが, 筋肉の活動レベルが下がっている」ということが挙げられた.

#### 5. 考察

前節で, ラフ集合を用いることによって上級者と中級者の違いを表すルールを導き出すことができた. ルールは最終的には専門家との議論が必要となるが, ルールそのものは非常に単純化されて理解しやすいため, 判断材料として大変有効に機能すると言える. 以上から, ラフ集合がスキルサイエンスの研究分野において有効なデータマイニング手法であると考えられる.

#### 6. 今後の課題

本稿では実験によって得られた生体データをラフ集合に適用させ, その有効性を検証してきた. しかしながら, 波形として得られたデータをラフ集合の属性化をする作業自体は, 半ば主観的な作業となっていた. 今後は時系列データマイニングとして動作パターン抽出の手法に用いられる, ピークタイミングシナジーモデル[植野 05]についての研究を進めたい.

また, 被験者数が少なかったため, 今後継続して実験を続け, また初級者についても同様の実験を行っていきたいと考える.

#### 7. 参考文献

- [五十嵐 03] 五十嵐創, 植野研, 森田想平, 尾崎知伸, 古川康一: ペイジアンネットワークを用いたチェロ演奏スキルのモデル化の試み, 第 07 回人工知能学会全国大会論文集, 2003.
- [Duntsch 00] Ivo Duntsch, Gunther Gediga: Rough Set Data Analys, Encyclopedia of Computer Science and Technology, vol.43, pp.280-300, 2000.
- [森 04] 森典彦, 田中英夫, 井上勝雄: ラフ集合と感性, 海文堂, 2004.
- [フレッシュ 64] カール・フレッシュ(佐々木庸一訳): ヴァイオリン演奏の技法 - 上巻, 音楽之友社, 1964.
- [ガラミアン 74] イヴァン・ガラミアン(アンカサス弦楽研究会訳): ヴァイオリン奏法と指導の原理, 音楽之友社, 1974.
- [植野 05] 植野研, 古川康一: ピークタイミングシナジーによる動作スキル理解, 人工知能学会誌, Vol.20, No3, pp.237-246, 2005.