



Title	時系列解析を用いたフィギュアスケートジャンプの分析システムの開発
Author(s)	
Citation	令和6（2024）年度学部学生による自主研究奨励事業研究成果報告書. 2025
Version Type	VoR
URL	https://hdl.handle.net/11094/101292
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

令和6年度大阪大学未来基金「学部学生による自主研究奨励事業」研究成果報告書

ふりがな 氏名	やまもと さとし 山本 悟資		学部 学科	工学部電子情報工学科	学年	3年
ふりがな 共 同 研究者氏名			学部 学科		学年	年
						年
						年
アドバイザー教員 氏名	櫻井 保志 / 設樂 哲弥		所属	産業科学研究所/ 人間科学研究科		
研究課題名	時系列解析を用いたフィギュアスケートジャンプの分析システムの開発					
研究成果の概要	研究目的、研究計画、研究方法、研究経過、研究成果等について記述すること。必要に応じて用紙を追加してもよい。(先行する研究を引用する場合は、「阪大生のためのアカデミックライティング入門」に従い、盗作剽窃にならないように引用部分を明示し文末に参考文献リストをつけること。)					

1 研究目的

本研究の目的は、フィギュアスケートのジャンプ動作を時系列データとして解析し、その精度を定量的に評価する学習モデルを構築することである。フィギュアスケートのジャンプは、回転数が増加するにつれて高度なバランスとタイミング調整が求められる複雑な技術であり、プロの選手にとっても安定して精度の高いジャンプを跳ぶことは困難である。また、フィギュアスケートの試合において、技の出来栄えを評価する「GOE (Grade of Execution)」の採点基準には「踏み切りから着氷までの身体の姿勢が非常に良い」といった曖昧な表現が多く、他の競技と比較して審査員の主観に影響されやすいという特徴がある。

このような状況において、練習で自身のジャンプの問題点を効率的に修正する手法や、試合で審査員の主観に依存しない客観的な評価指標があれば、選手にとって有益であると考えられる。本研究では、ジャンプ動作データを用いたモデル構築を通じて、選手の練習効率の向上と競技における公平な評価を実現するための手法開発を目指す。

2 研究方法

2-1 データの収集

研究において、氷上のジャンプ動作のデータを収集することが理想だが、リンクの使用条件や撮影制約により困難である。そのため、スケート選手が日常的な練習として行う陸上回転ジャンプを対象データとした。そしてデータ収集には大阪大学大学院人間科学研究科、生物人類学研究分野の設備である三次元動作解析システムを用いた。また、本実験では、大阪大学体育会フィギュアスケート部に所属する3級取得者1名を被験者とし、ジャンプの種類はシングルアクセルジャンプ(1回転半)に限定して解析を行った。ジャンプ動作の全身の特徴を詳細に捉えるため、被験者の全身にマーカーを装着し、ジャンプ動作を行った際のマーカーごとの動作データを取得した。適切なマーカー配置および実験方法の改良を目的として、事前にプレテストを1回実施した。その後、本計測を1回行い、

データ解析には本計測で得られたデータのみを使用した。

三次元動作解析装置は図1の赤丸で囲んだ8つの赤外線カメラから成り、そのカメラによってマーカーの動きを捉えることができる。そして本実験で用いるソフトウェアとして、高精度なモーションキャプチャデータの取得・処理・管理を可能にするプラットフォームであるOptiTrackのソフトウェア「Motive」の3.1.0 Beta 1バージョンを採用した。ジャンプ動作は非常に速い動きであるため、赤外線カメラがマーカーを見失うことがしばしば発生した。特に両腕部分は、ジャンプ時に腕を締める動作が加わり、複雑かつ素早い動きになるため、見失いが顕著であった。この問題に対応するため、両腕には、カメラがマーカーを見失った際に補間が可能となるよう、マーカー(図2)を図3のように3つ取り付けたフレームを被験者の両腕にテープで巻き付けて固定した。よって、全体で合計50個(=44個+補間用マーカー6個[3個×2])のマーカー位置をトラッキングし、データを取得した。44個のマーカーを貼付した位置(黒点)、補間用マーカーの位置(青点)、およびそれぞれのマーカー名称を図4に示す。



図2 マーカー



図3 補間用のフレーム

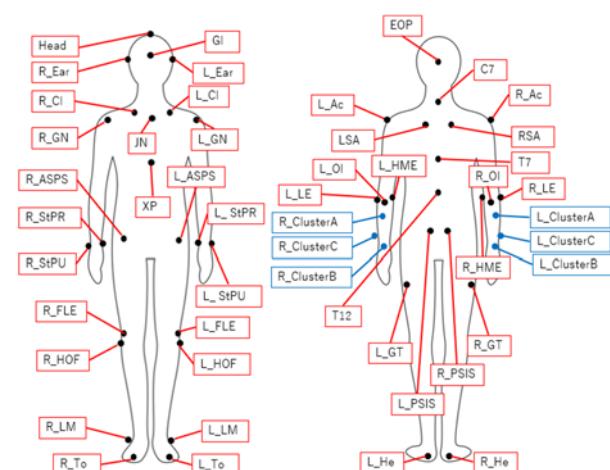


図4 正面(左)と背面(右)のマーカー位置と名称

そして被験者がジャンプ動作を行う間、各マーカーの位置座標を1秒間に120フレームの頻度で取得し、ジャンプ動作の開始から終了までを1つの時系列データとして取得した。得られたデータにおいて、一連のジャンプ動作の中で同一のマーカーが別のマーカーとして認識されている場合には、ソフトウェアを用いてそれらを結合した。また、データの欠損部分に対しては、ソフトウェアに搭載されている「Cubic」と「Pattern Based」の2種類の補間機能を使用して補間を行った。Cubic補間は、欠損したデータに対し、弧を描く形で補間する方法であり、短い時間範囲での欠損に適用した。一方、Pattern Based補間は、欠損したマーカーの周辺に位置する複数のマーカーを基準に、同様の軌道を描く形で補間を行う手法であり、欠損が比較的長い場合に適用した。それぞれ

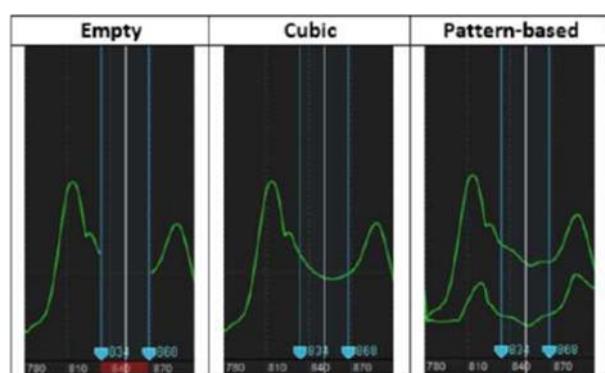


図5 Cubic補間とPattern Based補間
(Acuity Inc. (2019) p21の図表を一部修正)

の補間の様子は図5の通りである。なお、周囲のマーカーも含めて欠損しているデータについて補間が困難であったため、分析には使用しなかった。

従って、本測定で行ったジャンプ動作57回のうち、データ解析に使用可能であったのは41回分であった。これらのデータを「成功」、「両足着地」、「回転不足」、「ふらつき」の4種類に分類すると、それぞれ19、8、3、11個分の時系列データとなった。

2-2 モデルの作成

本研究では三次元の時系列データに基づき、クラスラベルを付与したデータセットを作成し、これをトレーニングセットとテストセットに分割して、Google Colab上のPythonによってモデルの構築を行った。本研究では、基となるモデルとして空間的および時間的な情報を同時に扱うことが可能な深層学習モデルであるSTGCN(Spatial-Temporal Graph Convolutional Network)モデルを採用した。STGCNモデルは、空間的特徴をグラフ畳み込み、時間的特徴を時間畳み込みによって学習することで、動作データの複雑なパターンを効果的に捉えることが可能である。その特徴として通常の空間的な接続に加えて図6のように時間軸(Temporal方向)に対しても接続を用意するので、ノード集合Vは以下のように表すことが可能である。

$$V = \{v_{ti} | t = 1, 2, \dots, T, i = 1, 2, \dots, N\}$$

ここでt、iはそれぞれ時間ステップとノード番号を表す。

本研究において、ノードはマーカーの位置とし、エッジは図7に示すように関節の接続や身体部位間の関係に基づいて設定した。グラフを視覚的にわかりやすくするために、右半身のエッジを赤色、左半身のエッジを青色、身体の中央部のエッジを緑色で示している。

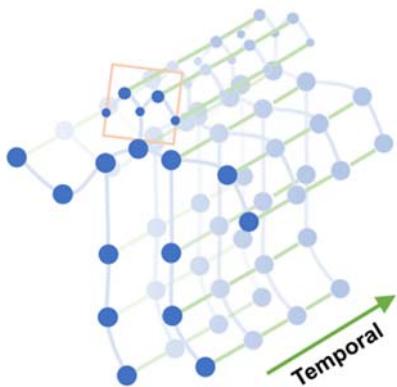


図6 STGCNのグラフ構造

出典：Sijie Yan(2018) p.1

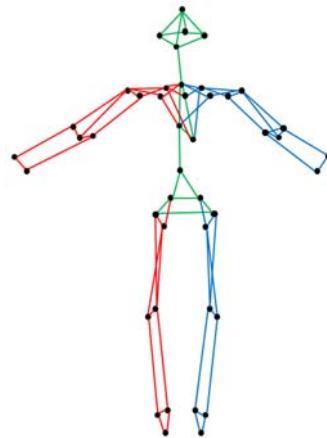


図7 入力したグラフ構造（正面向き）

各時系列データは一連のジャンプ動作のはじめから終わりまでのデータを持ち、その長さはデータごとに異なるため、パディング処理を行い、長さが足りない場合にはゼロを補填して、すべてのデータをフレーム数800の時系列データに統一した。また、モデルの精度向上にはデータ数が重要であるため、今回取得した41個の三次元時系列データに対して5フレームごとのフレームシフトを適用し、各データを25個の時系列データに増強することで、合計1025個の時系列データを使用できるようにした。そして今回構築したSTGCNモデルのネットワーク構造は表1の通りである。

層名	出力サイズ
入力層	(N, V * C, T)
STGC_block 1	(N, 64, T, V)
STGC_block 2	(N, 64, T, V)
STGC_block 3	(N, 128, T, V)
STGC_block 4	(N, 128, T, V)
STGC_block 5	(N, 256, T, V)
Global Average Pooling	(N, 256, 1, 1)
畠み込み層	(N, num_classes)

表1 STGCNモデルのネットワーク構造

まず、入力データは N : バッチサイズ、 V : グラフのノード数、 C : チャネル数、 T : フレーム数としてサイズ(N 、 V 、 C 、 T)のテンソルである。従って今回の実験ではバッチサイズを 16、ノード数はマーカーの数であるため 44、チャネル数は 3 次元の時系列データであることから 3、そしてフレーム数はパディング処理により 800 に統一されているので入力するテンソルのサイズは (16, 44, 3, 800) となる。このテンソルがまず入力層でノード数とチャネル数を掛け合わせた形でフラット化、そして正規化されて出力される。次に、STGC_block では、グラフ方向と時間方向のそれぞれに対して畳み込みを行っている。具体的には、空間時間グラフ畳み込みの各層において、隣接行列に学習可能なマスク M を導入することで、ノードの隣接ノードへの寄与を学習された重要度の重みに基づいて表現している。表よりこの STGC_block についてチャネル数を 64、128、256 と段階的に増加させながら繰り返し使用することで、モデルが処理できる特徴量の容量を増加させている。これにより、データ内の複雑なパターンやノード間の相関をより効果的に捉え、段階的に学習することが可能となる。そして、Global Average Pooling 層では空間的および時間的な特徴全体を平均化することで、最終的な特徴ベクトルを生成している。そして最後に畳み込み層によって、256 次元の特徴をクラス数 (num_classes = 4) にマッピングしている。また、今回はオプティマイザとして重み減衰により過学習を抑えながら効率的なパラメータ最適化を可能にする特性を持つ AdamW を採用した。

3 研究成果

データセット分割し、構築したモデルにおけるエポック数ごとのクラス分類の予測とその分類精度の結果を示す。但し、図 8 のクラスに関しては「成功」、「両足着地」、「回転不足」、「ふらつき」をそれぞれ Class1、2、3、4 としている。

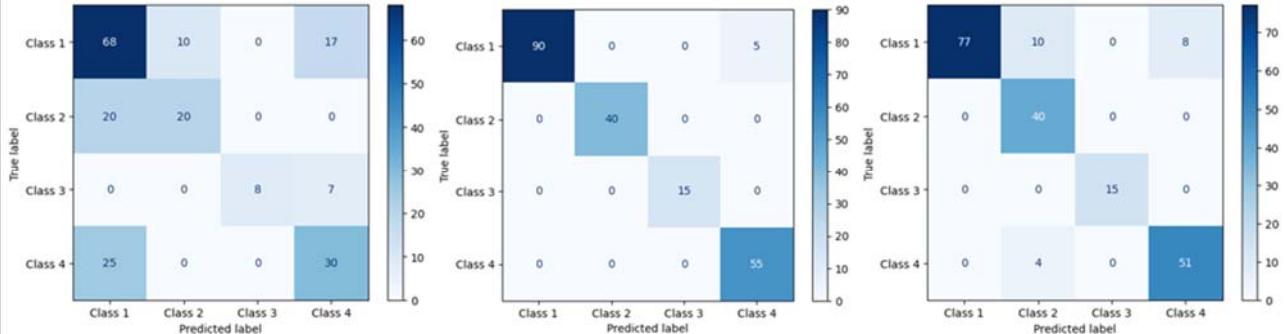


図 8 エポック数によるクラス分類精度の変化 (エポック数 : 5 (左)、 25 (中央)、 30 (右))

モデルの学習において、エポック数が小さい段階では、図 8 の左図に示すように予測ラベルと正解ラベルとのずれが大きく、テストデータに対する分類精度は 61.46% に留まった。しかし、エポック数が増加するにつれて分類精度が向上し、エポック数 25 では分類精度が 97.56% と非常に高い精度を達成した。この結果から、STGCN モデルがジャンプ動作の違いを正確に捉える能力を有していることがわかる。一方で、エポック数がさらに増加した場合には精度の向上が見られず、むしろエポック数 30 の分類精度は 89.27% に低下した。よって、本データセットに対する適切なエポック数は 25 程度であると考えられる。

4 今後の課題

本研究では、ジャンプ動作を比較的見分けがつきやすい 4 つのクラスで分類する手法を構築したが、

実用性を高めるにはクラスのさらなる細分化が必要である。フィギュアスケートにおける公平な採点を実現するためには、細かな姿勢のブレや動作の違いをより詳細に分類できるモデルの開発が求められる。加えて、本研究で対象としたジャンプはアクセルジャンプのみであり、他の5種類のジャンプや2回転以上のジャンプを解析対象に含めるには、さらに多くの動作データを取得する必要がある。また、選手ごとの体格の違いを考慮し、ジャンプ動作に特化した分析システムを構築しなければならないため、多様な被験者からのデータ収集が必要不可欠である。

また、STGCNはノード間、すなわちエッジの重みを学習によって決定するため、その重みに注目することで、モデルがクラス分類を行う際に重要なエッジを特定することが可能ではないかと考えた。これにより、モデルが予測を行う際に重要視しているジャンプ動作における関節や身体の位置関係を明らかにでき、選手が行ったジャンプ動作に対して、身体のどの部分が原因で失敗したのかを判別する手助けになることが期待される。

また、今回構築したモデルには学習に膨大な時間がかかるという問題点があり、効率的なアーキテクチャの採用や転移学習を活用したモジュールの再利用に加え、その他にも多くのアプローチが考えられる。例えば、データの増強技術や最適化手法の改善、モデルの軽量化など、さまざまな工夫を通じて、さらに実用性を高めることができると考えている。

従って、データ収集の面でもモデル構築の面でも本研究にはさらなる発展の余地が存在し、将来的な実用に向けて今後の改善と工夫を重ねていきたい。

5 謝辞

本研究の実施にあたり、3次元動作データの取得に向けて装置の準備やソフトウェアの操作指導をしていただいた人間科学研究科の設樂哲弥先生、研究室の受け入れやデータ解析の手法についてご指導いただいた産業科学研究所の櫻井保志先生、山中卓也先生ならびに特任研究員でいらっしゃる垣尾颯志さんに心より感謝申し上げます。

6 参考文献

- [1] Sijie Yan, Yuanjun Xiong, Dahua Lin. (2018) "Spatial Temporal Graph Convolutional Networks for Skeleton-Based Action Recognition", Association for the Advancement of Artificial Intelligence (AAAI)
- [2] Acuity Inc. (2019), "OptiTrack クイックスタートガイド_2.1:2.2" , https://www.acuity-inc.co.jp/wordpress/wpcontent/uploads/2023/11/OptiTrack_QuickStartGuide2.1_compressed.pdf