

AI を活用した子どもの動作発達評価システムの開発

香村恵介*

安藤英俊** 山北満哉*** 宮崎彰吾* 安藤大輔**** 大岡忠生***** 山田悟史*

抄録

子どもの動作発達を評価する方法の1つに、動きそのものに着目して質的な変化の過程を観察する方法がある。しかし、このような評価は、測定の信頼性や妥当性を担保するために評価者のトレーニングを必要とする上、評価に多大な時間を要する。そこで本研究では、人工知能(AI)の技術を活用することで、子どもの運動動作の解析から動作発達評価までを自動化する方法を開発することを目的とした。【方法】対象者は、プレゴールデンエイジにあたる3-8歳児とし、評価する運動動作は走動作とした。手順として、1)映像から骨格情報の自動取得、2)機械学習による各動作カテゴリーの予測を行う必要があると考えた。1)に関して、映像から自動的に姿勢推定を行うVideoPose3D(VP)を用いる手法と、FrameDIASを用いて人間が関節点をデジタイズする手法で算出した関節角度(上腕のスイング角度、離地時の膝関節角度、大腿の引き上げ角度など)を比較した。また、撮影方法による骨格情報の取得精度を比較するために、様々な撮影条件(fps、撮影方法)で撮影した走動作をVPに入力し、結果を比較した。2)に関して、機械学習に用いる教師データを作成するために、評価者2名でそれぞれ同じ対象者の動作評価を行い、評価が異なった動作カテゴリーに関しては協議をして評価を決定した。動作カテゴリーの分類には、サポートベクターマシン(SVM)を用いた多クラス分類を行い、評価者の算出した結果との一致度を分析した。【結果】FrameDIASとVPの各関節角度の差は、VPの2次元で算出した場合で最小3 deg、最大31 deg、3次元で算出した場合で最小5 deg、最大97 degであった。30 fpsで撮影した映像の場合、VPは撮影方法によらず、左右の腕・脚を正しく区別できなかったものの、60 fpsでは正しく関節点の取得が可能となった。一方、同一の対象者の走動作を固定カメラで撮影した場合と比較して、パンニング撮影した場合は、-11 degから38 degの範囲で差が生じていた。動作カテゴリーの分類精度は、腕振り46%、地面の蹴り方40%、足の蹴り上げ59%、大腿の引き上げ36%であった。これら4つの動作カテゴリーが人間の評価と完全に一致したのは10%、1つのみ不一致(3カテゴリーは正解)は19%であった。人間の評価者同士でも完全に一致したのは19%、1つのみ不一致は41%であった。【結論】本研究の手法では、子どもの走動作の発達段階の推定精度は低かった。機械学習の予測精度を上げるためには、映像からの骨格情報の取得精度をさらに上げるための工夫が必要である。また、教師データとなる人間側の評価の信頼性が低いことから、既存の評価基準を見直していく視点も必要かもしれない。

キーワード：幼児、発達、基本的動作、人工知能、姿勢推定

* 静岡産業大学経営学部 〒438-0043 静岡県磐田市大原 1572-1

** 山梨大学大学院総合研究部工学域 〒400-8511 山梨県甲府市武田 4-3-11

*** 北里大学一般教育部人間科学教育センター 〒252-0373 神奈川県相模原市南区北里 1-15-1

**** 山梨大学大学院総合研究部教育学域 〒400-8510 山梨県甲府市武田 4-4-37

***** 山梨大学大学院総合研究部医学域 〒409-3898 山梨県中央市下河東 1110

Development of a system for evaluating children's motor development using artificial intelligence

Keisuke Komura *

Hidetoshi Ando** Mitsuya Yamakita*** Shogo Miyazaki* Daisuke Ando****
Tadao Ooka***** Satoshi Yamada*

Abstract

This study aimed to develop a method to automate motion analysis for the evaluation of motor development by utilizing artificial intelligence (AI) technology. [Methods] Subjects were 3-8-year-old children, and their running motion was analyzed. The following procedure was performed: 1) Automatic pose estimation from video, 2) Prediction of each motion category by machine learning. Regarding 1), we compared the method of VideoPose3D (VP) that automatically performed pose estimation from video with the manual analysis of joint point by humans using FrameDIAS. We analyzed the arm swing angle, knee joint angle, and thigh lifting angle. We also filmed running motions under various camera conditions, entered the data into VP, and compared the results. Regarding 2), to create the training data for machine learning, two evaluators evaluated the running motion of the same subject. If the evaluations differed between the evaluators, they consulted each other. Multi-class classification of the motion categories was performed using a support vector machine (SVM). [Results] The difference between the joint angles of FrameDIAS and VP ranged from 3° to 31° (when calculated in two dimensions of the VP), and ranged from 5° to 97° (when calculated in three dimensions of VP). At 30 fps, the VP could not correctly distinguish between the left and right arms and legs regardless of the camera conditions, but at 60 fps, the joint points could be obtained correctly. Furthermore, when compared to a panning photograph, there was a difference in the range of -11° to 38°, than when the running motion of the same subject was filmed with a fixed camera. The motion category evaluation predicted by the VP and the human evaluation all matched 10%, and only one mismatch was 19%. The motion category evaluation between the human evaluator all matched 19%, and only one mismatch was 41%. [Conclusion] The method used in estimating motor development of children's running motion in the study had low accuracy. To increase the prediction accuracy of machine learning, it is necessary to increase the accuracy of pose estimation from video. Additionally, since human evaluation of training data has low reliability, it may be necessary to review existing evaluation standards.

Key Words : young children, development, motor skill, artificial intelligence, pose estimation

* Shizuoka Sangyo University, 1572-1, Owara, Iwata, Shizuoka

** University of Yamanashi, 4-3-11, Takeda, Kofu, Yamanashi

*** Kitasato University, 1-15-1, Kitasato, Minami-ku, Sagami-hara, Kanagawa

**** University of Yamanashi, 4-4-37, Takeda, Kofu, Yamanashi

***** University of Yamanashi, 1110, Shimokato, Chuo, Yamanashi

1. はじめに

子どもの運動発達を捉える方法には、運動を実施した結果に着目する方法と、動きそのものに着目して質的な変化の過程を捉える方法の2つが用いられる(日本学術会議、2017)。このうち、タイム、距離、回数などの運動の結果に着目する方法では、動作が未熟であっても体格が大きいことで良い結果を示す可能性があることに加え、一連の運動を構成するどの要素が未習熟であるかを判断することが難しい。このような理由から、動きそのものの発達を捉えることは重要である。また、日本学術会議は2017年の提言で、幼少期における「基本的な動きの未習得」は、体力向上に必要な運動強度や運動量の確保が困難となることで、将来への健康リスクにつながる可能性を指摘している。

現在、幼少期の子どもの運動発達を捉えるツールとして、海外ではTest of Gross Motor Development - 3rd edition (TGMD-3) (Ulrich, 2019)が代表的であるが、国内では幼児期運動指針(文部科学省、2012)の中で紹介されている中村ほか(2011)の基準が知られている。しかし、このような観察評価を行う際には、例えば走動作でいうと、腕は振れているか、膝は上がっているかなどと、いくつかの動作カテゴリーについて評価していく必要がある。そのため、録画した映像を繰り返し見る必要があり、評価に膨大な時間を要する。さらに、動作の判断基準に評価者の主観や個人差が含まれてしまう。

そこで、近年様々な分野に応用されている人工知能(Artificial intelligence: AI)の技術を応用することで、複雑で時間のかかる動作発達評価を「誰でも」、「手軽に」行うことが可能となると考えた。多数のデータを集めて評価することの「時間的」、「人的」負担が軽減されることで、これまでの多くの研究で今後の課題として指摘されつつ、実現に至っていない全国規模の評価基準の作成はもちろん、保育・教育場面などにおいても活用が期待される。






2. 目的

子どもの基本的動作の映像をAIで解析して、その発達段階を「簡単に」、「誰でも」、「即時に」評価できるシステムを開発すること。

3. 方法

幼児期運動指針(文部科学省、2012)で示されている基本的動作には、「走る(25m走)」、「跳ぶ(立ち幅跳び)」、「投げる(テニスボールの遠投)」、「捕る(ゴ

ムボールの捕球)」、「つく(ゴムボールのまりつき)」、「転がる(マットの上での前転)」、「平均台を移動する(平均台上の歩行・走行)」の7種類がある。本研究では、まずそれらの中でも代表的な動作である「走動作」の評価を行うこととした。走動作の観察的な評価(図1)には、5つの動作カテゴリーが設定されており、動作カテゴリーごとに3段階評価を行い、その評価に基づいて5段階評価が決まるようになっている。動作カテゴリーが決まれば、1-5点の動作得点は規則的に算出できるため、本研究では人間が評価した動作カテゴリーを予測できる学習モデルを構築することを目指した。

動作カテゴリー	動作得点	判断基準
 腕振り 1. 両腕のスウィング動作がない 2. 前方で腕をかくような動作 or 左右のバランスが悪い 3. 両肘の十分な屈曲 and 大きなスウィング	1	①, 4, 7, (10 or 11), 13
 接地時の足 4. 足の裏全体で 5. かかとから 6. 足の裏の外側から	2	②, (4 or 5), (7 or 8), 11, (13 or 14)
 地面の蹴り方 7. 膝が屈曲したまま and 垂直方向にキック 8. 水平方向にキックされるが十分な膝の伸展ない 9. 膝が十分に伸展し、水平方向にキック	3	2, (5 or 6), 8, ⑩, 14
 足の蹴り上げ 10. ほとんど蹴り上げなし 11. 小さな足の蹴り上げ 12. 続く大腿の引き上げにつながる十分な蹴り上げ	4	③, (5 or 6), 8, 12, 14
 大腿の引き上げ 13. ほとんど大腿の引き上げなし 14. わずかな大腿の引き上げ 15. ほぼ地面と水平の大腿の引き上げ	5	3, 6, ⑨, 12, 15

○ : Key category

図1. 走動作の観察評価(中村ほか、2011)

3.1. 骨格情報の取得

人間の評価を出力できる学習モデルを構築するには、その教師データ(正解データ)に対応した入力データが必要である。本研究では、映像から特徴点を検出し、姿勢推定を行う技術であるVideoPose3D(以下、VP)(Pavlo et al., 2019)を用いて関節点の座標を検出し、それらを元に関節角度を計算することで入力データとした。VPは入力映像の最も手前に映る人物を特定し、身体17点の2次元座標を取得することができる。そして、それらをもとに3次元の姿勢推定を行うことが可能である(図2)。各動作カテゴリーの予測に必要な特徴量として、「腕振り」は上腕のスィング角度および

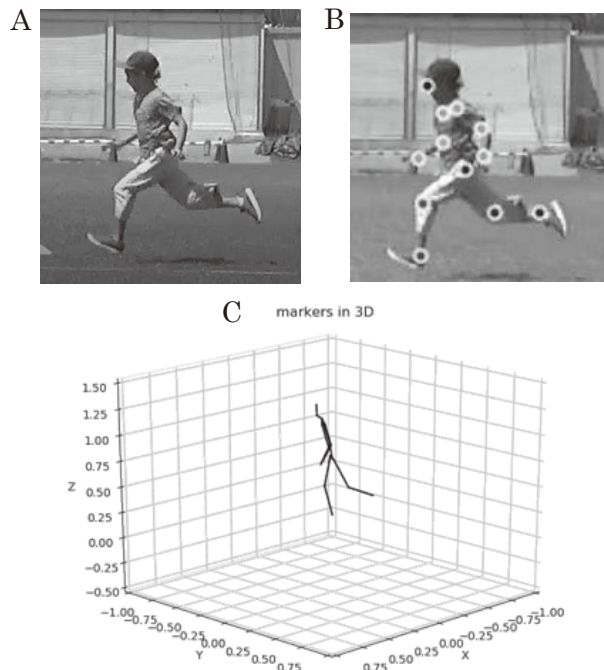


図2. VideoPose3Dの分析例

A: 入力映像、B: 2次元の姿勢推定、C: 3次元の姿勢推定

肘関節の最大角度、「地面の蹴り方」は離地時の膝関節角度、「足の蹴り上げ」は回復期の膝関節の最小角度、「大腿の引き上げ」は大腿の引き上げ角度が該当すると考えた。「接地時の足」については、VPは足関節を検出するが、つま先やかかとの点は検出できないため、今回は予測から除外した。しかし、「接地時の足」の動作カテゴリーは動作得点の判断基準において **Key category** に設定されていないため、総合的な評価に大きな影響はないと考えられる。

評価実験1として、スポーツ科学分野のキネマティクスの分析において使用される人間が映像を見て関節点をデジタイズする手法と、VPを用いた手法で上記の関節角度を算出し、VPを用いた手法にどれだけの精度があるかを検討した。小学1、2年生7人(男児3人、女子4人)に芝生上で50mの全力走を行わせた。スタートから25m地点の側方にビデオカメラ(SONY社製、FDR-AX60、露出時間1/1000 sec)を三脚に固定して設置し、60 fpsで撮影した。実長換算するために、20mと30m地点に各2点の構成マーカーを設置した。分析にはFrameDIAS 6 (DKH社製)を用いて、身体23点および4点の構成マークの2次元座標を読み取った。分析区間は、30m付近で左足が接地してから再び左足が接地するまでの1サイクル(2歩)とした。さらに、Butterworth digital filterを用いて6 Hzで平滑化した。VPでは、入力した映像から取得した2次元座標(VP2D)および3次元座標

(VP3D)から関節角度を計算した。両方の手法に共通して、関節角度の定義は図3の通りとした。

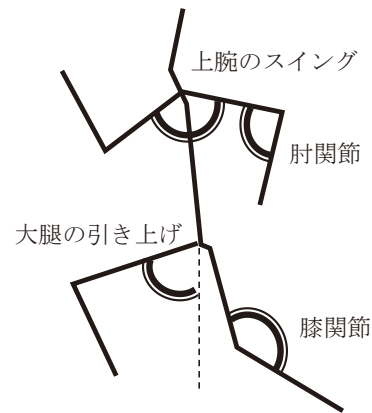


図3. 関節角度の定義

評価実験2として、撮影時の設定(フレーム数、解像度、カメラの撮影方法)がVPの姿勢推定に及ぼす影響を探索的に検討した。3歳および7歳の子ども2人の走動作(25mまたは50m走)を1) 30 fpsおよび60 fps、2) 1280×720、1440×1080、3840×2160(4K)、3) 固定またはパンニングで撮影して、骨格情報の取得精度を比較した。また、現場では高品質の映像を撮影することが困難である場合もあることから、深層学習を用いてフレーム補間を行うSuperSlomo (Jiang et al., 2018) や、低解像度画像から高解像度画像を生成するTecoGAN (Chu et al., 2019) を用いて、映像を加工した場合の姿勢推定についても検証した。

評価実験3として、同一人物の走動作を固定カメラで撮影した映像とパンニング撮影した映像で、VPによる姿勢推定にどれくらい差があるかを検討した。年少児5名の25m走を側方から2台のビデオカメラ60 fps、露出時間1/500 sec)で固定およびパンニング撮影した。パンニング映像では、画面手前側の左目のKey pointのY座標と左足首のKey pointのY座標との差が最大値の場合のフレームから、固定映像で対象が映っていたフレーム数を使用した。

なお、VPの動作環境は、OS Ubuntu 18.04 LTS、GPU Geforce GTX 1080、使用プログラミング言語はPythonであった。

3.2. 学習モデルの構築および精度の検証

本研究では動作カテゴリーの分類にサポートベクターマシン(SVM)の多クラス分類を適用した。これは、データの分布からクラス間の境界を自動で探す機械学習の手法である。教師データには各動作カテゴリーの人間側の評価結果を用いた。人間側の評価を行う者は

2 時間の評価トレーニングを受け、同一の評価を行うことができるようにした。その上で、評価者2名でそれぞれ同じ対象者の動作評価を行い、評価が異なった動作カテゴリーに関しては協議をして評価を決定した。各動作カテゴリーの入力データとした特徴量の動作は、3.1.で述べた通りである。使用したデータは、幼稚園2園および小学校2校の子どもの213映像であった。

予測した動作カテゴリーの精度は、教師データと完全に一致した割合（例：予測された動作カテゴリーが2、8、12、14、人間側の評価も2、8、12、14）お

び1つのみ不一致の割合（例：予測された動作カテゴリーが2、8、12、14、人間側の評価が1、8、12、14）を算出した。

4. 結果及び考察

4.1. 骨格情報の取得（評価実験1-3）について

機械学習の入力データとして用いる特徴量を算出するにあたり、3つの評価実験を行った。評価実験1の人間が映像を見て関節点をデジタイズする手法と、VPを用いた手法の比較結果を表1に示した。

表1. FrameDIASとVideoPose3Dの姿勢推定結果の比較

	Sub.1	Sub.2	Sub.3	Sub.4	Sub.5	Sub.6	Sub.7	FrameDIASとの差 deg				FrameDIASとの差 %				
	deg	deg	deg	deg	deg	deg	deg	最小	最大	平均	(SD)	最小	最大	平均	(SD)	
上腕のスイング角度																
FrameDIAS		42	85	55	98	41	86	103								
VP2D		68	94	60	105	57	102	93	-10	26	10	(11.4)	-10	64	20	(24.1)
VP3D		39	73	56	69	51	53	75	-33	9	-13	(17.0)	-38	23	-13	(21.4)
肘関節の最大角度																
FrameDIAS		160	128	165	122	137	112	151								
VP2D		169	142	168	143	145	125	166	3	21	12	(5.5)	2	17	9	(4.9)
VP3D		63	72	74	70	42	56	105	-97	-47	-70	(22.5)	-69	-31	-50	(12.7)
離地時の膝関節角度																
FrameDIAS		135	138	150	137	152	147	144								
VP2D		139	133	159	139	149	150	147	-5	9	2	(4.7)	-4	6	1	(3.2)
VP3D		149	163	136	131	149	140	142	-14	25	1	(13.5)	-9	18	1	(9.7)
回復期の膝関節の最小角度																
FrameDIAS		59	74	55	77	48	55	41								
VP2D		62	57	61	65	57	46	72	-18	31	1	(16.3)	-24	76	8	(33.8)
VP3D		126	122	127	121	118	103	102	44	72	58	(11.5)	57	149	106	(37.2)
大腿の引き上げ角度																
FrameDIAS		50	44	50	48	55	52	57								
VP2D		63	50	62	71	60	58	66	4	23	11	(6.5)	8	47	21	(13.6)
VP3D		39	31	34	40	29	47	46	-26	-5	-13	(6.7)	-47	-10	-25	(12.2)

全て画面の手前側（左側）の動作を分析した値, FrameDIASは2次元実長換算で算出した値

VP2D: VideoPose3Dの2次元座標から算出, VP3D: VideoPose3Dの3次元座標から算出

表2. VideoPose3Dを用いた撮影方法別の姿勢推定結果の比較

	Sub.1	Sub.2	Sub.3	Sub.4	Sub.5	固定との差 deg				固定との差 %				
	deg	deg	deg	deg	deg	最小	最大	平均	(SD)	最小	最大	平均	(SD)	
左上腕のスイング角度														
固定		154	138	150	131	146								
パンニング		154	144	168	132	149	0	18	6	(7.2)	0	12	4	(4.8)
右上腕のスイング角度														
固定		115	107	70	101	106								
パンニング		114	116	83	97	96	-10	13	1	(9.5)	-9	18	2	(11.0)
肘関節の最大角度														
固定		89	87	56	75	99								
パンニング		95	97	81	78	118	3	25	13	(9.1)	4	44	17	(16.1)
離地時の膝関節角度														
固定		132	106	86	123	126								
パンニング		121	110	124	128	129	-11	38	8	(17.8)	-8	44	9	(19.9)
回復期の膝関節の最小角度														
固定		51	42	51	53	61								
パンニング		51	51	51	53	56	-4	8	1	(4.7)	-7	20	2	(10.2)
大腿の引き上げ角度														
固定		55	61	41	52	59								
パンニング		53	63	49	56	58	-2	7	2	(3.6)	-3	18	5	(8.2)

表3. 正解データと予測データの一致率 (%)

動作カテゴリー	全映像 n=213	固定 n=128	パンニング n=85
腕振り	46	58	49
地面の蹴り方	40	55	36
足の蹴り上げ	59	66	42
大腿の引き上げ	36	59	26
完全一致	10	19	5
1つのみ不一致	19	30	13

表4. 人間同士の評価の一致率 (%)

動作カテゴリー	固定 n=128
腕振り	62
地面の蹴り方	65
足の蹴り上げ	66
大腿の引き上げ	66
完全一致	19
1つのみ不一致	41

FrameDIAS と VP の各関節角度の差は、VP の 2 次元で算出した場合で最小 3 deg、最大 31 deg、3 次元で算出した場合で最小 5 deg、最大 97 deg であった。このことから、3 次元の姿勢推定は特徴量の算出には不適切であることが示唆された。また、2 次元の手法でもある程度の誤差が生じることが明らかとなった。

評価実験 2 として、撮影時の設定（フレーム数、解像度、カメラの撮影方法）が VP の姿勢推定に及ぼす影響について検討した。その結果、1280×720（固定）または 1440×1080（パンニング）の条件で、どちらも 30 fps で撮影した映像の場合、VP は撮影方法によらず、左右の腕・脚を正しく区別できないことが目視で確認された。4K の解像度かつ 60 fps で撮影した映像の場合、左右の腕・脚の入れ替わりを正しく区別し、精度が向上したものの、一部、映像を処理しきれないことがあり、不安定であった。この理由として、VP が 4K 映像の処理に対して適合していない可能性が考えられる。そのため、60 fps のまま解像度を落として再解析した結果、正しく関節点の取得が可能となった。30 fps から 60 または 120 fps に映像を加工した場合でも、正しく関節点の取得できた。このことから、VP の手法を用いて特徴量を取得する場合、60 fps 以上のフレーム数で撮影することが必要であると示唆された。しかしながら、子どもの動作撮影を行う現場では 30 fps の映像で撮影する場合も多いことが予想される。この場合、先述したようにそのまま 30 fps の映像を VP に入力すると腕や脚の左右の区別が不安定になってしまう。そこで、SuperSlomo による 30 fps から 60

fps への加工を行ってから VP で分析した。しかし、SuperSlomo をかけた映像の中で一部、映像が乱れるケースが存在した。そこで、30 fps の映像で同一フレームを 4 つずつ複製して VP で解析することで、腕や脚の左右の入れ替わりを正しく区別できるようになった。これは、VP が動画の時系列情報を活用して姿勢推定を行う手法であることが関係しているかもしれない。

また、加工して映像の解像度を上げても、姿勢推定の精度の向上は確認できなかったため、解像度は骨格情報の取得精度に影響しないと考えられる。評価実験 2 の結果から、30 fps の映像は同一フレームを複製すること、そして VP に入力する映像はなるべく 60 fps 以上で撮影することで姿勢推定の精度を向上できることが示唆された。

評価実験 3 として、固定カメラで撮影した映像とパンニング撮影した映像を用いた場合に、VP による姿勢推定にどれくらい差があるかを検討し、結果を表 2 に示した。固定カメラで撮影した場合と比較して、パンニング撮影した場合は、-11 deg から 38 deg の範囲で差が生じていた。最も差が大きくなったのは肘関節の最大角度であり、肘関節の動作は姿勢推定が難しいことが示唆された。

4.2. 動作カテゴリーの分類精度

機械学習を用いた動作カテゴリーの分類精度を表 3 に示した。動作カテゴリーの分類精度は、腕振り 46%、地面の蹴り方 40%、足の蹴り上げ 59%、大腿の引き上げ 36% であった。これら 4 つの動作カテゴリーが人間の評価と完全に一致したのは 10%、1 つのみ不一致（3 カテゴリーは正解）は 19% であった。このことから、人間側の評価を自動で算出できるモデルを構築するには、さらなる改善が必要である。

一方、表 4 に示したように、人間の評価者同士でも完全に一致したのは 19%、1 つのみ不一致は 41% であったことから、トレーニングを積んだ人間同士でも、同一の評価を出すことは難しい。これは、例えば地面の蹴り方の動作カテゴリーでは、「ほとんど蹴り上げがない」、「小さな足の蹴り上げがある」、「十分な足の蹴り上げがある」などといった曖昧な基準をもとに評価者の主観で評価をつけるために、安定した評価ができないことが考えられる。

今回は映像からの姿勢推定に VP を使用したが、この分野は日進月歩であるため、より精度の高い姿勢推定の手法が開発される可能性もあるため、動向を注視しつつ、最善の方法を用いていくことが望まれる。ま

た、今回の検討ではVPによる3次元姿勢推定の精度は低かったが、運動動作の多くは3次元的な動きを伴う。3次元姿勢推定を精度よく行うことのできる手法が登場すれば、飛躍的に予測精度が向上することも考えられる。さらに、近年のCG技術を用いて、子どもの走動作に特化した学習モデルをつくるために、CG映像を教師データとして学習させていくことも考えられるかもしれない。

今後の課題として、機械学習の予測精度を上げるために、映像からの骨格情報の取得精度をさらに上げるための工夫が必要である。また、教師データとなる人間側の評価の信頼性が低いことから、既存の評価基準を見直していく視点も必要かもしれない。

5. まとめ

本研究では、映像から自動で姿勢推定を行い、子どもの動作発達段階を評価する方法を検討した。その結果、現状では人間を超える評価精度を出すことができなかった。学習モデルを構築する際に必要な姿勢推定の入力データの精度を向上させていくことが第一に必要である。また、教師データとする人間側の評価が不安定であることも学習モデルの作成にとって厳しい点である。映像からの姿勢推定が高い精度でできるようになれば、そもそも主観的な動作カテゴリーの評価をする必要もなく、動作発達に有用なデータを即時にフィードバックできるため、今後は姿勢推定の精度向上に注力してもよいかもしれない。

【参考文献】

- Chu et al. (2019) Learning Temporal Coherence via Self-Supervision for GAN-based Video Generation.
- Jiang H et al. (2018) Super SloMo: High Quality Estimation of Multiple Intermediate Frames for Video Interpolation. CVPR.
- 文部科学省 (2012) 幼児期運動指針ガイドブック.
- 中村ほか (2011) 観察的評価法による幼児の基本的動作様式の発達. 発育発達研究, 51: 1-18.
- 日本学術会議 (2017) 提言子どもの動きの健全な育成を目指して～基本的動作が危ない～.
- Pavlo D et al. (2019) 3D human pose estimation in video with temporal convolutions and semi-supervised training. CVPR: 7753-7762.
- スポーツ庁 (2018) 平成29年度体力・運動能力報告書. 体力・運動能力の年次推移の傾向 (青少年) .

Ulrich DA (2019) Test of gross motor development (3rd ed.). Austin, TX: Pro-Ed.

この研究は笹川スポーツ研究助成を受けて実施したものです。

