

動作時系列の分類のための関節位置に基づく 特徴量について

南直輝¹ 小西一輝¹ 皆川拓海¹ 今村誠¹

概要: スポーツ, ヘルスケア, 工場での生産活動, および, 監視などの分野で, 深度センサや加速度センサを用いた人間の動作解析方式がさかんに研究されるようになった. 従来の多くの研究では, 特定の動作毎にカスタマイズされた特徴量が用いられることが多かった. そこで, 多様な動作の分類する識別力をもった一般的な特徴量セットとして, 関節特徴マップを提案する. 関節特徴マップとは, 関節と関節とを結ぶベクトルのなす角である関節角度の時間遷移によって動作を特徴づける素性のセットであり, 関節を適切に選択することによって多様な動作を識別できるようになる. 本稿では, 関節特徴マップを用いた動作分類方式を提案すると共に, 典型的な 10 種のストレッチ動作を対象として, 動作分類が可能であることを示す.

キーワード: 時系列分類 動作解析 深度センサ 関節角度

Features Based on Joint Angle Transition for Classifying Human Motion Time Series

NAOKI MINAMI¹ KAZUKI KONISHI¹
TAKUMI MINAKAWA¹ MAKOTO IMAMURA¹

Abstract: Human motion analysis using depth sensors or accelerometers have been actively studied in sports, healthcare, factory production and surveillance. Most existing works use specifically designed features depending on target motions. This paper proposes universal features called joint-feature-map to discriminate whole body motions. Joint feature map is a set of time transition of joint angles, which are described with the angles formed by vectors from one joint to another joint. Various possible selections of joints enable joint-feature-map to discriminate variety of motions. This paper proposes a joint-feature-map based motion classification method and shows that our method can discriminate 10 typical whole body stretch motions

Keywords: Time series classification, motion analysis, Depth sensor, Joint angle

1. はじめに

IoT(Internet of Things)の普及に伴って, 人の動作に伴う加速度, ジャイロ, 音, 動画などのデータから人の行動を認識することにより, 健康, 製造, 監視, 交通などに活用されるようになった^{[1][2]}. 例えば, ヘルスケアのための行動や動作の解析^{[3][4][5]}, 製造等の作業分析などへの応用^{[6][7][8]}が研究されている.

従来研究では, 対象とする動作に応じた特徴量を対象とする問題に応じて設計することが多かった. そのため, 新たな動作を対象とする際に, 新たな設計が必要になるという課題があった. 本稿では, 人間の動作を解析にすることにあたって, より一般的な特徴量のセットを提案することを目的として, 関節角度(参考文献[4]で導入された)に対する時間遷移を用いた新たな特徴量のセットを提案する. そして, 全身の運動動作を含むストレッチ体操[9]の動作分類実験を通じて, 提案方式の妥当性を検討する.

本論文の構成は以下の通りである. 2 章では, 人の全身運動動作を識別するための基本的な特徴量として, 関節角

度遷移を定義する. 3 章では, 全身動作の分類のための特徴量のセットとして, 動作分類に重要となる関節角度遷移を並べた関節特徴マップを提案する. そして, 関節特徴マップを用いた動作分類方式を提案する. 4 章では, ストレッチ体操の教本[9]から典型的な動作 10 種を選択して, 動作分類実験の評価結果を報告する. 5 章では, まとめと今後の課題を述べる.

2. 全身動作の特徴量: 関節角度遷移

本章では, 本稿で新たに提案するストレッチ動作の特徴量(素性)である関節角度遷移について説明する. 以下では, まず, 本稿で扱う関節と, 関節角度遷移で用いる関節角度を説明した後, ストレッチ動作全体の特徴量である関節角度遷移について述べる.

2.1 Azure が対象とする関節と関節位置

本稿では, 関節位置の遷移を対象とするので, センサとしては, Microsoft 社の深度センサ Azure Kinect[10] (以下, Azure と呼ぶ)を用いた. Azure は, 図 1 に示す 32 個の関節のトレンドデータ, すなわち, 時間毎の位置を出力する.

¹ 東海大学
Tokai University

また、Azure のサンプリング周期は 15FPS であり、座標の軸は、図 2 に示すように、X 軸は Azure から被写体に向かうベクトルからみて右方向を正とする軸、Y 軸は下方向を正とする軸、Z 軸は Azure から撮影対象に向かう方向を正とする軸となっている。そして、Azure が出力するデータは、時間毎の関節毎の 3 次元ユークリッド空間上の位置である。すなわち、認識する関節名を A、時間を t とするとき、関節位置の遷移を表現する 3 次元の実数値の組 $A(t)$ を返す。図 3 に、ストレッチ動作「エイエイオー！スクワット」の手首位置の X 軸、Y 軸、Z 軸の位置の遷移を順に示す。




図 1 関節の位置と名称




図 2: Azure の座標軸




図 3: Azure が出力する関節位置の遷移

2.2 関節角度と関節角度遷移

同時刻のある関節位置から別の関節位置へのベクトルを関節ベクトルと呼ぶ。すなわち、時間 t における関節 A から関節 B へのベクトル $\vec{A}(t)B(t)$ を関節ベクトルと呼ぶ。以下では、関節ベクトルの位置は必ず同じ時間なので、関節ベクトルの表記として時間 t を省略して、 \vec{AB} 等と表記する。

関節角度とは、ある関節 A を支点とするとき、関節ベクトル \vec{AB} と関節ベクトル \vec{AC} のなす角度 $\arg(\vec{AB}, \vec{AC})$ である。角度は、A を支点として左回りに計測するものとする。たとえば、図 4 に、ストレッチ動作「エイエイオー！スクワット」の体を屈めた態勢を左に示し、体を伸ばした態勢を右に示す。図 4 の肘を中心とする関節角度は、肘を支点として、肘から手首への関節ベクトルと肘から肩への関節ベクトルのなす角度 $\arg(\vec{肘手首}, \vec{肘肩})$ を示している。以下では、より簡潔に、 $\arg(\vec{AB}, \vec{AC})$ を $A(B,C)$ と表記する。例

えば、 $\arg(\vec{肘手首}, \vec{肘肩})$ は、肘[手首, 肩]と表記する。

図 4 では、ストレッチ動作「エイエイオー！スクワット」を特徴づける 3 つの関節角度「肩[肘, 尻]」、「肘[手首, 肩]」、「膝[尻, 足首]」を示した。




図 4 関節角度の例

関節角度が定義できれば、関節角度の時間遷移が定義できる。この関節角度の時間遷移を、関節角度遷移とよぶ。たとえば、図 5 に、ストレッチ動作「エイエイオー！スクワット」の関節角度「肩[肘, 尻]」、「肘[手首, 肩]」、「膝[尻, 足首]」を示す。図 5 の角度計算は、生データに対して 0.3 秒の時間平均をしたものである。




図 5: 関節角度の遷移トレンドの例

3. 提案方式：関節特徴マップを用いた全身動作の分類

3.1 全身動作の記述実験

2 章で導入した Azure で抽出可能な関節角度遷移によって、ストレッチ動作を特徴付けることができるかを検証するために、ストレッチ体操の教本[9]に記載されている 48 動作に対して、各々の動作を特徴づける関節角度遷移を手で抽出した。この抽出実験の結果、「体幹をひねる運動」や「動きが小さい運動」、「肩や腕、手首を回す運動」などの場合を除くと、48 中 33 は、関節角度遷移によって、互いに識別可能であると分かった。表 1 に典型的なストレッチ

動作 10 種と各々の動作を特徴づける関節角度遷移を示す。

表 1 ストレッチ動作を特徴づける関節角度遷移

動作名	関節角度の遷移
エイエイオー！スクワット	(1) 肘[肩, 手首]180→90, 180→90 (2) 膝[尻, 足首]180→90, 180→90 (3) 肩[肘, 尻]180→90, 180→90
手首フリフリ	(1) 肘[肩, 手首]180 一定 (2) 肩[尻, 肘]90 一定 (3) 尻[へそ, 膝]90 一定 (4) 膝[尻, 足首]90 (5) へそ[骨盤, 首]180 一定
「言えませーん！」でバツェン運動	(1) 肘[肩, 手首]90→180 (2) 膝[尻, 足首]90→180 (3) 肩[尻, 肘] 90→210
全力疾走 10 秒チャレンジ	(1) 肘[肩, 手首] 90 一定 (2) 肩[尻, 肘]90 → 0 → 90 (3) 骨盤[へそ, 膝] 120 一定
かにさんかかとタッチ腹筋	(1) 肘[肩, 手首]70 → 180 (2) 肩[尻, 肘] 100→60 (3) 骨盤[へそ, 膝] 90→70→90→120→90 (4) 膝[尻, 足首] 90 一定
スイカ割り腹筋	(1) 肘[肩, 手首] 180 一定 (2) 肩[尻, 肘] 180 → 90 (3) 骨盤[へそ, 膝] 180 → 90 (4) 膝[尻, 足首] 180 → 90
お腹のぜい肉を引き締めるパイパイ	(1) 肘[肩, 手首] 180 一定 (2) 肩[尻, 肘] 180 一定 (3) 骨盤[へそ, 膝] 180 → 160 → 180 → 200 → 180 (4) 膝[尻, 足首]180 一定
いやだいやだの横っ腹運動	(1) 肘[肩, 手首] 90 一定 (2) 肩[尻, 肘] 90 一定 (3) 尻[へそ, 膝] 180→45 (4) 膝[尻, 足首] 180→90 (5) へそ[骨盤, 首] 180→150
背筋使って「お歳暮どうぞ！」	(1) 肘[肩, 手首] 180 一定 (2) 肩[尻, 肘] 180→90 (3) 骨盤[へそ, 膝] 180 一定 (4) 膝[尻, 足首] 180 一定 (5) へそ[骨盤, 首]180→160
「雨、降ってるかな？」腹斜筋運動	(1) 肘[肩, 手首] 180 一定 (2) 肩[肘, 尻] 90 一定 (3) 膝[尻, 足首] 180 一定

3.2 関節角度遷移に基づく全身動作の表現：関節特徴マップ

関節角度は0度から360度まで連続的に変化するが、前節の分析から、ストレッチ動作では、角度は比較的大きく変化していることがわかった。したがって、30度、45度、90度などの離散的な刻み幅を設定して、その刻み幅の範囲の動作遷移を素性として扱うことにより、ストレッチの動作特徴を素性ベクトルとして表現できることが期待できる。

例えば、関節角度「肘[肩, 手首]」が180度から0度に連続的に遷移する動作の場合には、その動作は素性「肘[肩, 手首] 180° → 90°」の値が1で、素性「肘[肩, 手首] 90° → 0°」の値が1であると規定する。以下では、この素性を角度遷移素性と呼ぶ。

この方法に従えば、簡単のために、関節角度として、肩[尻, 肘], 肘[肩, 手首], 膝[尻, 足首]の3種類をたてて、角度遷移としては、90一定, 180一定, 0→90, 90→180, 90→0, 180→90の6種類をたてれば、組み合わせで得られる素性は3×6の18種類あり、それぞれの素性に対応する関節角度遷移を含む場合は1、含む場合は0とすれば、ストレッチ動作の表現として、18次元の二値ベクトルが定義できる。

本稿では、この二値ベクトルの視認性を向上させるために、関節角度を行、角度遷移を列とする3行6列の二値の行列で表記し、関節特徴マップと呼ぶ。関節特徴マップの1を黒、0を白で表現すると、表1の「エイエイオー！スクワット」から得られる関節特徴マップは図6のようになる。同様に、「スイカ割り腹筋」の特徴マップは、関節角度を肩[尻, 肘], 肘[肩, 手首], 膝[尻, 足首]に限定すると、図7となる。

エイエイオー！スクワット			
	肩[肘・尻]	肘[肩・手首]	膝[尻・足首]
90一定			
180一定			
0→90			
90→0			
90→180			
180→90			

図6: 「エイエイオー！スクワット」の関節特徴マップ

スイカ割り腹筋			
	肩[肘・尻]	肘[肩・手首]	膝[尻・足首]
90一定			
180一定			
0→90			
90→0			
90→180			
180→90			

図7: 「スイカ割り腹筋」の関節特徴マップ

3.3 関節特徴マップによる全身動作分類

機械学習の分類における正解データに相当するストレッチ動作は関節特徴マップで表現できることがわかった。したがって、Azure データから関節角度遷移を抽出して特徴マップを抽出して、特徴マップの類似度が最も大きい正解ストレッチを出力すれば、動作データの分類ができるはずである。すなわち、図8に示すように、学習フェーズとして、被験者から収集したストレッチ動作データ(教師動作データ)から関節特徴マップを抽出して、関節特徴マップとラベル(ストレッチ動作名)からなる教師データを作成する。ついで、分類フェーズとして、新たに被験者から抽出したストレッチ動作データ(検証用動作データ)から関節特徴マップを抽出して、その特徴マップを教師データと比較して最も類似する関節特徴マップをもつストレッチ動作名を出力すればよい。

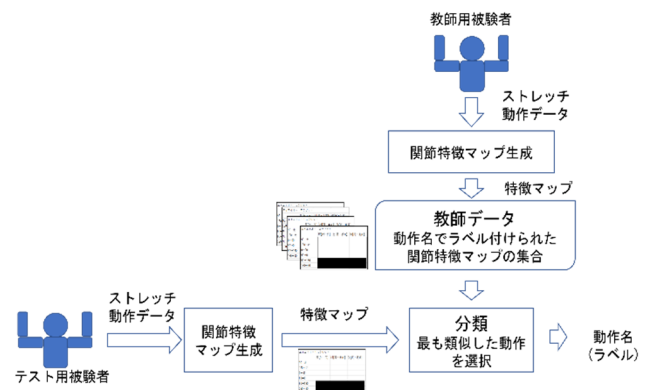


図8: 関節特徴マップを用いた機械学習による動作分類

4. 評価

4.1 評価実験の方法

(1) 対象動作と関節角度の選択

評価実験では、提案方式の妥当性を確認するために、ストレッチ体操の教本[9]の48の動作から全身運動という観点から、対象動作としては典型的な10種の動作(表1)を選択し、また、関節角度としては代表的な3種(肩[尻, 肘], 肘[肩, 手首], 膝[尻, 足首])を選択した。

(2) 教師データの作成

ラベル付けされた動作データから、特徴マップとラベル(ストレッチ動作名)と対になった教師データを生成することもできるが、本評価実験では、特徴マップ表現の妥当性を評価しやすいように、教師データは3.2節で述べた人手で作成した関節角度遷移を用いた。以下では、この教師データを特徴マップテンプレートと呼ぶ。

(3) データの前処理

Azure が取得したデータは、ノイズを除去するために、

前処理として、窓サイズ 0.3 秒(5 フレーム)で時間変換を実施した。窓サイズを大きくすると、ノイズ除去の能力は高まるが、関節角度の感度は低下するというトレードオフの関係にある。

(4) 実験システムの構成

実験システムの構成を図 9 に示す。実験システムは、Microsoft の Azure、関節角度抽出、特徴マップ抽出、ストレッチ動作分類からなる。Azure は、2メートル離れた被験者のストレッチ動作の動画データから、32 種の関節位置の軌跡データを出力する。関節角度抽出は、関節位置トレンドデータ(時間に対して関節位置を写像する関数)から 2 章で述べた方法を用いて、3 種類の関節角度のトレンドデータ(図 5)を出力する。特徴マップ抽出は、関節角度抽出から特徴マップの次元に相当する角度遷移素性を抽出することにより、関節角度トレンドデータから関節特徴マップを出力する。最後の、ストレッチ動作分類では、被験者動作の特徴マップと、10 種の特徴マップテンプレートとのユークリッド距離を計算し、距離が最も小さい動作を出力する。

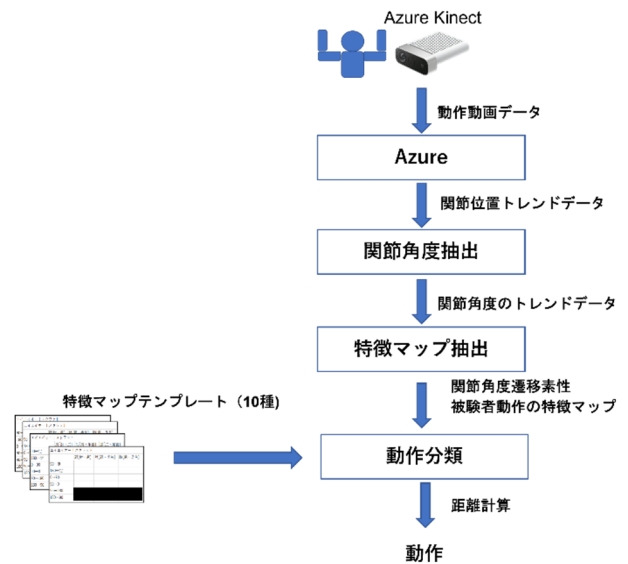


図 9: 実験システムの構成

4.2 評価結果

評価では、ストレッチ動作 10 種毎に 2 人の 2 個の動作データを収集し、計 40 個の動作データを分類した。表 2 に動作毎の精度(適合率, 再現率, F 1 値)を示し、表 3 に混同行列を示す。

表 2 ストレッチ動作の分類精度

		ストレッチ動作									
		1	2	3	4	5	6	7	8	9	10
適合率		0.57	1.00	1.00	1.00	0.67	0.75	1.00	1.00	1.00	1.00
再現率		1.00	1.00	1.00	0.13	0.75	0.75	1.00	1.00	1.00	1.00
F1 値		0.73	1.00	1.00	0.22	0.71	0.75	1.00	1.00	1.00	1.00

表 3 ストレッチ動作の混同行列

		予測値									
		1	2	3	4	5	6	7	8	9	10
ストレッチ動作	1	4	0	0	0	0	0	0	0	0	0
	2	0	4	0	0	0	0	0	0	0	0
	3	0	0	4	0	0	0	0	0	0	0
	4	2	0	0	0.5	1.5	0	0	0	0	0
	5	0	0	0	0	3	1	0	0	0	0
	6	1	0	0	0	0	3	0	0	0	0
	7	0	0	0	0	0	0	4	0	0	0
	8	0	0	0	0	0	0	0	4	0	0
	9	0	0	0	0	0	0	0	0	4	0
	10	0	0	0	0	0	0	0	0	0	4

動作 A の適合率とは、動作 A と予測したデータ数における正しく予測できたデータの割合である。また、再現率は、正解ラベルが動作 A のデータ数における予測できた割合である。

$$\text{適合率} = \frac{\text{正しく予測できたデータ数}}{\text{動作 A と予測したデータ数}}$$

$$\text{再現率} = \frac{\text{正しく予測できたデータ数}}{\text{正解ラベルが動作 A のデータ数}}$$

また、表 3 では、予測した動作が複数あった場合は、正解を予測動作数で割ったものとした。例えば、二つの動作を予測して正解を含んでいる場合には、正しく予測できたデータ数は 1/2 としてカウントした。

4.3 考察

「全力疾走 10 秒チャレンジ」(図 10)の再現率が 0.13 と低い理由は、腕を前後に動かす動作において、肘と手首は Azure から被写体に対する方向に動くので、座標が正確にとれないためである。「肘[手首, 肩]」の関節角度は 90° とほぼ一定のはずであるが、図 11 の真ん中のトレンドグラフに示すように正確にとれていないことがわかる。「スイカ割腹筋」でも、手首が Azure から被写体に対する方向に動く成分があるため、「肘[手首, 肩]」の 180° 一定がうまくとれないことがあり、動作推定に失敗する場合があった。これらの分類失敗の原因は、Azure の関節推定の誤りなので、この誤りを解消する方策としては複数の Azure により関節位置を推定することにより、Azure の死角をなくすことが考えられる。

「エイエイオー！スクワット」の適合率が 0.57 と低い理由は、「全力疾走 10 秒チャレンジ」と「スイカ割腹筋」を誤って認識したものが「エイエイオー！スクワット」に分類されたことによる。したがって、「全力疾走 10 秒チャレンジ」と「スイカ割腹筋」における手首の位置を正確に取得できれば、これらの誤りは解消できる。

「カニさんかかとタッチ腹筋」の誤りは、「膝(尻, 足首)」の角度が正確にとれていない時間帯があったことによる。この動作では、手首と足首が重なる時間帯があり、そこで足首が手首によって隠れたために、足首の位置が正確にとれなかったことが原因である。

今回対象とした 10 種の動作分類では、失敗の原因は Azure が推定した関節位置の誤りにあるので、関節特徴マップの表現能力は十分であったと考えられる。




図 10: 「全力疾走 10 秒チャレンジ」の関節角度




図 11: 「全力疾走 10 秒チャレンジ」の関節角度の遷移

5. まとめと今後の課題

本稿では、人の全身運動動作を識別するための特徴量として、関節角度遷移に基づく関節特徴マップを提案し、10 種類の全身ストレッチ動作に対する分類実験を通じて、特徴量の表現能力が十分であることを検証した。今後の課題としては、「対象動作種類の拡大による関節特徴マップの精緻化」、「教師データ作成も含めた動作分類」、そして「複数台 Azure による関節位置の精度向上」があげられる。

(1) 対象動作種類の拡大による関節特徴マップの精緻化

今回は 10 種類にしぼった実験を実施した。対象動作を Azure で取得可能な関節で識別が可能と思われる 32 種の動作に拡大すると共に、使う関節データの種類や関節角度を増やすなど、関節特徴マップの表現能力を向上させることは今後の課題になる。

(2) 教師データ作成も含めた動作分類

今回の実験では、関節特徴マップの表現能力の評価を主

な目的としたため、正解の関節特徴角度は人手で与えていた。分類精度のロバスト性を向上させるために、「正解とする関節特徴マップを教師データから自動生成する」、また、「教師データから閾値を自動的に定める」なども今後の課題である。

(3) 複数台 Azure による関節位置の精度向上

評価考察の結果、関節が Azure から被写体に対する方向に動く場合は、認識精度が低下することがわかった。複数台の Azure を用いることにより、センサの死角をなくすことで、関節位置の取得精度を向上させることも今後の課題になる。

参考文献

- [1] J.K. Aggarwal and M.S. Ryoo : “Human activity analysis: A review”, ACM Computing Surveys, vol. 43, no. 3, p. 103-146 (2011)
- [2] A. Bulling, U. Blanke, and B.Schiele : “A tutorial on human activity recognition using body-worn inertial sensors”, ACM Computing Surveys, vol. 46, no. 3, p. 118-151 (2014)
- [3] 大内一成, 土井美和子. 携帯電話搭載センサによるリアルタイム生活行動認識システム. 情報処理学会論文誌, vol. 53, no. 7, p. 1675-1686 (2012).
- [4] 津田純慈・飯村遊大・鳥井郁洋・伊藤薫・山口雄平・岡野菜々・寺田昌弘・今村誠: 「運動練習支援システムのための関節ベクトルモデルを用いたガイダンス生成方式」, 電気学会論文誌 C, Vol.140, No.3, p. 364-374 (2020).
- [5] 寺田 昌弘, 矢合 忠生, 松原 直也, 三宅 紘生, 飯村 遊大, 井上 真生, 今村 誠: 腰痛予防のための荷物持ち上げ動作の解析方式, 電気学会論文誌 C , Vol.140, No.12, p. 1369-1379 (2020).
- [6] 宇田吉弘, 吉田和広, 村田嘉利. 深度カメラを用いたピッキング工程における作業ミス検知システム. 情報処理学会論文誌, コンシューマ・システム論文, vol. 6, no. 1, p. 63-74 (2016)
- [7] Y. Namioka, D. Nakai, K. Ohara, T. Maekawa : “Automatic Measurement of Lead Time of repetitive Assembly Work in an Factory Using a Wearable Sensor”, Journal of Information Processing, vol.25, p. 901-911 (2017).
- [8] 寺田 昌弘, 皆川 拓海, 安齋 博人, 今村 誠: 加速度時系列データからの反復作業パターンの教師なし発見方式, 電気学会論文誌 C, Vol. 141 No. 9, p. 1039-1047 (2021).
- [9] 片岡 信和: かたおか気象予報士の毎朝 10 秒! 楽しく「お天気ストレッチ」, 幻冬舎 (2021).
- [10] Microsoft: Azure Kinect, <https://azure.microsoft.com/en-us/services/kinect-dk/>