

GPS を用いた複数センサデータの同期と 局所的相互相関にもとづく動作分類

石田和成^{†1}

本研究では GPS と 3 軸加速度, 3 軸角速度, 3 軸磁気で構成される 9 軸センサを用いた動作計測装置を開発した。また, 動作分類を行うため, 複数の計測装置により計測した身体の一部の各部位の時系列データについて, 相互相関にもとづき類似度を定義した。相互相関は 2 つの時系列データの類似性を確認するための標準的な指標である。しかし, 同一の動作系列により構成される 2 つの時系列データにおいて, 個々の動作速度や動作間の間隔が異なる場合, 相互相関は低い値を示す。そのため, 時系列データの各時点において局所的な相互相関を求め, 特徴的な複数動作を抽出し, それらの相互相関の平均にもとづき類似度を定義する。ただし, 時系列データの各時点において局所的相互相関を計算するため, 時系列長の増大は計算量の増大をもたらす。この増大を軽減, 漸進的な局所的相互相関計算アルゴリズムを開発した。この手法によりスポーツデータを分類した結果, 個々の動作速度や動作間の間隔が異なる場合でも, 本手法は通常の相互相関による類似度を用いた分類と比較し, 適切に動作分類できることを確認した。

Analysis of Actions based on Local Cross Correlation and Synchronized Data of Multiple Sensors with GPS

KAZUNARI ISHIDA^{†1}

We developed action measurement units with three axis accelerometers, three axis gyroscopes, 3 axis digital compasses, and GPS. In order to categorize actions based on multiple time series data collected from the measurement units, we also developed a classification method of time series data with local cross-correlation function. In order to measure similarity between two time series data, a cross-correlation function gives a similarity measure. However, the function is not suitable for the measure, when there is big difference between two actions in terms of speed, although the two actions consist of same motions. In order to avoid the problem of different speed, we introduce a local cross-correlation function. The similarity measure is defined as an average of the multiple local cross-correlation values on local maximum peaks. However, computation time for the measure tends to be easily increasing with long time series data. In order to reduce the computation time, we formulated an incremental calculation of the local cross correlation. We calculated two types of similarities on forty three time series data concerning sports with our method and normal cross correlation. According to the result, we confirmed that our method can clearly separate same type of sports data into a same category.

1. はじめに

時系列データについて, 相互相関にもとづき類似度を定義し, スポーツデータの動作分類を行った。2 つの時系列データ間の相互相関は類似度指標として広範に用いられる。しかし, スポーツデータの分析に用いる場合, 動作速度の違いにより問題が生じる。例えば定められた複数の動作を定められた順番で行う場合, 動作間の間隔や動作の速度が異なるデータの相互相関は低い値となる。そのため, 本研究では, 時系列データにおいて局所的に相互相関を求め,

その平均にもとづき類似度を定義する。ただし, 時系列データ全域で局所的相互相関を計算するため, 時系列長の増大にともない計算量が増大する。この増大を防ぐため, 漸進的な局所的相互相関計算アルゴリズムを開発する。また, 得られた局所的な相互相関にもとづき, スポーツデータの分類を行う。

人間の行動を分析するための手法として, 近年, 急速に普及した MEMS(Micro Electro Mechanical Systems)内臓のスマートフォンを用いた, 行動センシングが実世界に広がりを見せている 1)。植田ら(2013)は, スマートフォンのセンサを用いた行動センシングと行動推定を行った 2)。

ヘルスケア, スポーツといった計測対象については, 独自

^{†1} 広島工業大学
Hiroshima Institute of Technology

の機器が必要となる場合がある。森田(2010)らは、リハビリテーション効果の定量化、歩行計測のため、3軸の加速度、角速度、地磁気センサデータを、Bluetoothで転送できるシステムを開発した3)。Avciら(2010)は、慣性センサを用いた、ヘルスケア、スポーツアプリケーションのための活動識別を行った4)。

アクションスポーツについて、Crockettら(2007)は、スケートボードの推進力の力学的分析を行うために、トレッドミルでの滑走をモーションキャプチャシステムで分析した5)。Campilloら(2007)は、BMXのsprocketに測定装置を装着し、ペダリングの角速度や力を計測、分析した6)。Jasonら(2008)は、スノーボードのハーフパイプ競技におけるエアリアル動作について、加速度、角速度センサを用いて、分散分析にもとづく分類を行った7)。それらに対し、本研究では、スノーボードのオフシーズントレーニングにも用いられる、車輪で滑走するビッグエアランプにおいて、3種目のアクションスポーツ（スケートボード、インラインスケート、BMX(Bicycle Motocross)）について、滑走データの分類を行う。

2. 動作計測システムの開発

アクションスポーツは活動範囲が広いので、モーションキャプチャで動作の記録が難しい。それに対してMEMSを身体に装着した計測であれば、活動範囲が広い場合も問題は無い。MEMSが利用できる汎用小型デバイスとして、スマートフォンの活用が考えられる。しかし、身体の数多くの部位に機器を装着し、時間的に同期したデータを取得するには、正確なタイムスタンプが必要である。またアクションスポーツは動きが激しいため、耐衝撃性のある機器を用いる必要がある。そのため、独自に動作計測システムを開発することとした。

2.1 ハードウェア

動作計測装置は、マイコン(Arduino Fio)、3軸加速度、3軸角速度センサ(MPU6050)、3軸地磁気センサ(HMC5883L)、GPS(MTK3339)を組み合わせ開発した。データの記録にはSDカードを用いた。センサのサンプリング周波数は50Hz程度である。SDカードに記録されるデータは、GPSの時刻と位置、または加速度ジャイロ磁気の9軸センサデータが、1レコードに記録される。

2.2 ソフトウェア

収集したデータは次の流れで処理を行う。

(1) タイムスタンプの変換

データの記録時刻を秒に変換し、データの整列を行う。GPSモジュールのデータは受信状況によって、不完全なデータが記録される場合があるため、このクリーニングも併せて行う。

(2) タイムスタンプの調整

GPSから得られたタイムスタンプの調整を行う。今回用い

たGPSの周波数は10Hzのため、サンプリング周波数50Hzのデータの複数のレコードに同じタイムスタンプが付いている。そのため、線形補間によりタイムスタンプを付け直す。

(3) データの同期化

複数の動作計測装置から得られたデータの同期化を行う。データの全タイムスタンプでレコードソートを行い、データの無い部分については、直前のデータの値を用いた補間を行う。

(4) タイムスタンプの均等化

データ分析を行うには、データの時間幅を均等化する必要がある。記録装置のサンプリング周波数50Hzのデータの劣化を避けるため、10ms間隔でデータ時間幅の均等化を行う。各タイムステップにおいてデータの無い部分については、直前のデータの値を用いた補間を行う。

(5) アクションの検出

各アクションを検出し個別ファイルに出力する。計測したデータは長い時系列となるため、各アクションを手動で抽出するのは大変な作業である。そのため、センサ値を用いて、各アクションを自動検出し、個別ファイルに記録することとした。

3. 分析対象と動作分類手法

本研究では、ビッグエアランプにおける、3種目のアクションスポーツ（スケートボード、インラインスケート、BMX(Bicycle Motocross)）について、滑走データの分類を行う。ビッグエア競技はX-gamesにおける競技種目であり、2018年に韓国のピョンチャンで開かれる冬のオリンピック種目としてスノーボードのビッグエアが採用されるなど、近年注目を集めている。ビッグエアランプは、1つのストレートジャンプ用のキッカーランプと、1つのバーティカルランプで構成される（図1）。また、これら2つのランプでのジャンプやエアに必要な滑走速度を得るためにスロープを用いる。ビッグエアランプには、いくつかの種類のサイズがあるが、本研究では図1に示す、幅広い技能レベルの被験者が滑走可能な、比較的小型のランプを用いる（図における単位はmm）。

種目の違いはジャンプやエアにおける体の動きの違いとして現れる。言い換えると、同一種目の滑走については、体の動きの類似性は高い。そのため本研究では滑走データ間で相互相関を求めることにより滑走間の類似性を定量的に評価する。ただし、同一種目の場合であっても、同一技能レベルが異なる場合、滑走速度やジャンプ、エアのタイミングが異なる。そのため、単純に相互相関を用いるだけでは、同一種目であっても、技能レベルの異なる滑走について類似性を正しく評価できない。そのため、本研究では相互相関を求める時間幅を制限し、局所的な相互相関を求め、高い相互相関を示す複数の動作時点の平均値を用いた類似




図 1 ビッグエアランプ

Figure 1 Big Air Ramp

性を定義する。

3.1 局所的相互相関

本研究では局所的相互相関を動作類似性の指標として用いる。そのため、局所的な平均、局所的な分散を求める。まず、時系列データの 1 点を $y_{c,i,j,t}$ とすると、局所的な平均は式(1)で求める。

$$Y(p, w, c, i, j) = \mu_{c,i,j,w,p} = \frac{1}{w} \sum_{t=1}^w y_{c,i,j,p+t} \quad \dots (1)$$

ここで、滑走(c)、センサ装着部位(i)、センサ軸(j)、窓サイズ(w)、窓開始時刻(p)、窓内時刻(t)である。時系列長(l)とすると、窓開始時刻(p)の範囲は[0, l-w]である。1つの時系列データ全域についてすべての窓開始時刻(p)における局所的な平均の計算を行う。式(1)を用いて時系列データの開始位置で求めた平均値にもとづき、以下の更新式を用いて次の窓開始時刻(p)における局所的な平均値を求めることができる。

$$Y(p, w, c, i, j) = Y(p-1, w, c, i, j) - \frac{1}{w} (y_{c,i,j,p} + y_{c,i,j,p+w}) \quad \dots (2)$$

局所的な分散は式(3)で求める。

$$V(p, w, c, i, j) = \frac{1}{w-1} \sum_{t=1}^w (y_{c,i,j,p+t} - \mu_{c,i,j,w,p})^2 \quad \dots (3)$$

平均の場合と同様に、分散の場合も、時系列データ開始位置で求めた値にもとづき、以下の更新式(4)(5)を用いて、次の窓開始時刻(p)における分散を求める。

$$V(p, w, c, i, j) = \frac{1}{w-1} V2(p, w, c, i, j) + \frac{w-2}{w-1} Y(p, w, c, i, j)^2 \quad \dots (4)$$

$$V2(p, w, c, i, j) = V2(p-1, w, c, i, j) - y_{c,i,j,p}^2 + y_{c,i,j,p+w}^2 \quad \dots (5)$$

次に 2 つの時系列データ間における局所的共分散の計算について説明する。2 つの時系列データ間の開始時刻シフト(k)については、データ 1 よりデータ 2 を前時刻にシフトする場合と、後時刻にシフトする場合がある。以下では前時刻にシフトする場合の計算方法を説明する。ここで、シフト(k)(前時刻にシフトする場合 $k < 0$)、2 つの時系列データの重なる期間(l)(前にずれる場合 $\min(n1, n2-k)$ 、 $n1, n2$ は

それぞれ各時系列データのデータ点数)、窓サイズ(w)($w \leq l$)とする。データ 1 はデータの開始から、データ 2 はデータのシフト(k)に応じてデータ開始時刻から k 進んだ時刻を起点として計算に用いられる。滑走 1(c1) と滑走 2(c2)についての局所的共分散は式(6)(7)(8)により計算される。

$$D(p, w, k, c1, c2, i, j) = \sum_{t=1}^w (y_{c1,i,j,p+t} - \mu_{c1,i,j,w,p}) (y_{c2,i,j,p-k+t} - \mu_{c2,i,j,w,p-k}) \quad \dots (6)$$

$$D(p, w, k, c1, c2, i, j) = D2(p, w, k, c1, i, j) + D2(p, w, k, c2, i, j) - 2 \cdot Y(p, w, c1, i, j) \cdot Y(p-k, w, c2, i, j) \quad \dots (7)$$

$$D2(0, w, k, c1, i, j) = \sum_{t=1}^w y_{c1,i,j,t}^2 \quad \dots (8)$$

平均、分散の場合と同様に、共分散の場合も、時系列データ開始位置で求めた値にもとづき、以下の更新式(9)を用いて、次の窓開始時刻(p)における分散を求める。

$$D2(p, w, k, c1, i, j) = D2(p-1, w, k, c1, i, j) - y_{c1,i,j,p}^2 + y_{c1,i,j,p+w}^2 \quad \dots (9)$$

局所的相互相関は、局所的共分散と 2 つの時系列の局所的分散を用いて、式(10)(11)(12)にもとづき計算する。

$$C_{c1,c2,i,j,k,w,p} = \frac{D(p, w, k, c1, c2, i, j)}{s_{c1,i,j,w,p} \cdot s_{c2,i,j,k,p+w}} \quad \dots (10)$$

$$s_{c1,i,j,w,p} = \sqrt{V(p, w, c1, i, j)} \quad \dots (11)$$

$$s_{c2,i,j,k,p+w} = \sqrt{V(p, w, c2, i, j)} \quad \dots (12)$$

平均、分散、共分散の計算を更新式により求めることにより、局所的共分散の計算量を大幅に削減することができる。たとえば、局所的期間として窓サイズ(w)を 200 とした場合、通常の計算を行う場合と比べ、計算量は約 200 分の 1 に削減される。サンプリングを 100 分の 1 秒間隔で行ったデータに窓サイズ 200 を用いる場合、局所的期間の長さは 2 秒となる。

今回計測装置は、比較的動作の安定した部位として、(1) 頭部、(2) 腹部、(3) 右足首、(4) 左足首に付けることとした。この場合、9 軸センサを 4 つ用いるため、最大 36 次元の滑走データが得られる。滑走データの各次元について局所的相互相関を求め、滑走データ間の類似度として用いる。

3.2 所的相互相関のピーク検出と類似度定義

2つの滑走データ間の局的相互相関のピーク検出と類似度の定義について説明する．本研究では，固定サイズのウィンドウを時系列データ上でスライドさせ，ウィンドウ内の極大値が得られる時刻を，局的ピークの発生時刻として用いる．このピーク検出を用いる理由は，通常用いられる平滑化や近似曲線を用いた時系列データのピーク検出では，ピーク発生時刻が曖昧になるためである．

1つのセンサの時系列データ系列を y とし，ウィンドウサイズを s とするとき，関数 localpeak を時刻 t における局的ピーク u_i における値 v_i とその発生時刻 q_i を返す関数とする．また， U を局的ピークの集合とする．局的ピーク数 n はウィンドウサイズ s により変化する．

$$u_i = \{v_i, q_i\} = \text{localpeak}(y, s, t) \quad \dots (13)$$

$$U = \{u_1, u_2, \dots, u_n\} \quad \dots (14)$$

得られた局的ピーク集合 U に含まれるピーク u_i を，所的相互相関の値により降順に並べ替えたリスト L を関数 decendingsort により求める．またリストの先頭要素を得る関数 head により，最大ピーク u^{1st} を取得し，時点 q^{1st} をアクション検出範囲の中心とする．

$$L = \text{decendingsort}(U) \quad \dots (15)$$

$$u^{1st} = \text{head}(L) \quad \dots (16), \quad u^{1st} = \{v^{1st}, q^{1st}\} \quad \dots (17)$$

この時点 q^{1st} を中心とし，閾値 r で定めた時間範囲 $[q^{1st} - r, q^{1st} + r]$ において，有効なピークを抽出する．そのため，関数 range を用いて，最大ピークの得られる時刻 q^{1st} を基準とし，閾値 r にもとづき，ピーク集合 L から有効時間範囲内の極大ピーク集合 R を取得する．

$$R = \text{range}(L, q^{1st}, r) \quad \dots (18)$$

さらにピークの最大値 v^{1st} を基準とした割合 p にもとづき， $v^{1st} \times p$ 以上の値が得られた局的ピークを，有効なピークとして選定する関数 peak を用いて，有効ピーク集合 P を構成する．

$$P = \text{peak}(R, v^{1st}, p) \quad \dots (19)$$

予備実験により閾値 p として 0.6 を用いた．また時間範囲の閾値 r は 500 とした（実時間で 5 秒）．これは，1回の滑走における主要動作が 5 秒の範囲に収まる場合の指定である．2つの滑走間の類似度は，関数 average を用いて得られた局的ピークの値 $\{v^1, v^2, \dots, v^m\}$ の平均で定義する（ m は有効ピーク数）．

$$\text{Similarity} = \text{average}(P) \quad \dots (20)$$

上記で述べたピーク検出，類似度にもとづき，各滑走間の類似性を計算し，局的ピークの得られる時系列の組み合わせデータを出力するソフトウェアを開発した．

3.3 滑走データの特徴

ビッグエアランプの滑走データにおいて，直感的に動作が把握できるセンサの値は，Z 軸加速度センサである．これは，このセンサにおいて直立姿勢時に重力加速度が計測されるためである．ここでは比較的安定した部位として頭部の Z 軸加速度センサの値を用いて特徴を示す．




図2 BMX 上級者 1,2 の滑走データ

Figure 2 Trajectories of Advanced BMX 1 and 2




図3 BMX 初級者と上級者の滑走データ 1

Figure 3 Trajectories of Beginner and Advanced 1




図4 BMX 初級者と上級者の滑走データ 2

Figure 4 Trajectories of Beginner and Advanced 2

図2はBMX 上級者 1 (Data1)，2 (Data2) の滑走データを示すグラフである．グラフ横軸は時間（単位時間は 10

ミリ秒), 縦軸はZ軸加速度センサの値である。グラフにおいて2か所, 加速度が0に近い区間があり, 1つ目はストレートジャンプ, 2つ目はパーティカルランプでのエアによる無重力状態を示す。ジャンプ, エア中は自由落下となるため, 加速度は0に近い値となる。また, 同一技能レベルの滑走であるため, 2つのグラフはほぼ同じタイミングでジャンプとエアが行われていることが分かる。

図3, 4はBMX初級者(Data1)と上級者(Data2)の滑走データを示す。図3は局所相互相関の最大値が得られる滑走データの組み合わせである。図4は5番目の値が得られる組み合わせである。図3はパーティカルランプでのエア部分で, 図4はストレートジャンプでそれぞれ局所相互相関の極大値が得られる。図3, 4に示すように, 本手法は, 技能レベルが異なるデータ間の類似度計算において, 滑走時に行う2つの動作を考慮していることがわかる。

4. 実験

実験には図1に示したビッグエアランプを用いた。競技として, スケートボード, インラインスケート, BMXを選定した。パーティカルランプでの滑走は被験者の得意な方向でターン, またはエアを行うものとした。ターン, エアの方向は, 右回転(RIGHT)と左回転(LEFT)の2種類である。また, 被験者の滑走技術を初級(BEGINNER), 中級(INTERMEDIATE), 上級(ADVANCED)の3段階に区分した。初級者はストレートジャンプランプをジャンプせず滑走する。中級者はストレートジャンプを行うが, パーティカルランプはコーピング下でのターンを行う。上級者はストレートジャンプおよびパーティカルランプでのコーピングを越えたエアを行う。被験者の延べ人数は10人, 滑走は3~5セットを行い, 43の滑走データを得た。各滑走データについて, 3.1, 3.2で示した提案手法により, 各滑走データ間の距離を求めた。

4.1 局所的相互相関による分類

提案手法の類似度にもとづき階層的クラスタリング(ウオード法)を行い, 同一種目, 同一技能レベル毎にクラスターが形成されることを確認した(図5)。図の左側から, BMX, インライン(INLINE), スケートボード(BOARD)のクラスターで構成されている。各クラスターは, BEGINNER, INTERMEDIATE, ADVANCEで構成される。BOARDクラスターは, BOARD(RIGHT, ADVANCED)に加えてBOARD(LEFT, ADVANCED)も含まれる。全43データのうち, 2つの滑走データについて, BMX(RIGHT, ADVANCED)がBMX(RIGHT, INTERMEDIATE)に, BOARD(RIGHT, BEGINNER)がBOARD(RIGHT, INTERMEDIATE)にそれぞれ分類され, 滑走技能レベルの分類に若干誤りが見られた

が, その他の41データについては, 種目別, 技能別で明確なクラスターが形成されている。

4.2 従来手法による分類

通常の相互相関を用いる手法を用いた場合の結果では, 滑走技能のレベルについて, 上級とそれ以外(中級, 初級)で大まかな分類がなされる(図6)。これは, 滑走技能の違いは滑走速度の違いをもたらし, ジャンプとエアとの間の時間幅に大きな差異が生じるためである。時系列データ全域についての相互相関を用いる場合, この時間幅の違いは同一種目の滑走の場合でも相互相関の値の大きな低下をもたらす。そのため従来の手法では滑走技能レベルが異なる場合, 同一種目の滑走が遠く離れたクラスターに分類され, 正しく分類できていないことが分かる。また, 初級(BEGINNER)と中級(INTERMEDIATE)のクラスターの分類は不十分である。加えて, 全43データのうち, BMX(RIGHT, BEGINNER), INLINE(RIGHT, ADVANCED)の2データに分類の誤りが見られた。

5. おわりに

本研究では, アクションスポーツの動作解析を目的とした, 動作計測システムを開発し, 局所的相互相関にもとづき, ビッグエアランプにおける各種アクションスポーツの動作や技能レベルを分類するための手法を提案した。この分類手法は, 競技者の技能測定や, 動作の自動抽出に利用できると考えられる。

参考文献

- 1) 西尾信彦, 河口信夫: 実世界に広がる装着型センサを用いた行動センシングとその応用, 情報処理別冊, Vol. 54, No. 6, 562-563, (2013).
- 2) 植田 智明, 杉村 博, 松本 一教, 一色 正男: センサデータからの人間の行動推定, 情報処理学会研究報告, グループウェアとネットワークサービス, 86(30), 1-5, (2013).
- 3) 森田祐也, 岡本淳, 川村和也, 関雅俊, Salvatore SESSA, Massimiliano ZECCA, Zhuohua LIN, 石井裕之, 高杉紳一郎, 高西淳夫, 藤江正克: 加速度センサを用いた左右分離床反力推定方法の検討, 生活生命支援医療福祉工学系学会連合大会講演論文集, 489-491, (2010).
- 4) Akin Avci, Stephan Bosch, Mihai Marin-Perianu, Raluca Marin-Perianu, Paul Havinga: Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications - A Survey, Architecture of Computing Systems (ARCS), 2010 23rd International Conference, Hannover, Germany, (2010).
- 5) Benjamin A. Crockett, Randall L. Jensen: Kinematic Analysis and Muscular Activity of Skateboard Propulsion in Experienced Participants, 25 International Symposium on Biomechanics in Sports, 602, Ouro Preto, Brazil, (2007).
- 6) Philippe Campillo, Timothee Doremus, Jean-Michel Hespel: Pedaling analysis in bmx by telemetric collection of mechanic variables, Brazilian Journal of Biomotricity, 1(2), 15 - 27, (2007).
- 7) Jason W. Harding, Colin G. Mackintosh, Allan G. Hahn, Daniel A. James: Classification of Aerial Acrobatics, Proceedings of 7th Snowboarding Using Inertial Sensors ISEA CONFERENCE 2008, Biarritz, June 2-6, (2008).




Figure 5 Cluster by Proposed Method




Figure 6 Cluster by CCF