

剣道上達支援のためのIMUを用いた打突動作認識

鳥越 庸平¹ 高田 将志¹ 中村 優吾^{1,2} 藤本 まなと¹ 荒川 豊^{1,3} 安本 慶一¹

概要: スポーツ分野における情報技術の活用は競技者のパフォーマンスの向上やトレーニングプロセスの強化に繋がると期待されている。特に、慣性計測装置 (IMU: Inertial Measurement Unit) の活用はスポーツパフォーマンスの分析において大きな可能性を秘めていると考えられており、今後 IMU を活用したスポーツパフォーマンスの分析が、これまで注目されていなかった様々なスポーツに展開・応用されることが期待できる。本稿では、様々なスポーツ競技の中でも特に、日本の伝統的なスポーツ競技の一つとして認知されている剣道に着目し、剣道上達支援システムの実現に向けた第一段階として、IMU を用いた打突動作の認識手法を新たに提案する。具体的には、6 人の被験者を対象に、右手首、腰、右足首、竹刀鐔、竹刀先革に取り付けられた IMU から得られる加速度及びジャイロデータを基に、打突動作の分類を行なった。対象とする打突動作は、剣道において最も一般的な「面」、「突き」、「胴」、「小手」の 4 種類と、打突箇所を左右を加えた 8 種類とし、機械学習アルゴリズムとして Random Forest (RF) を用いて評価した。同一被験者のデータのみで学習した結果、右手首、腰、右足首のデータの組み合わせにおいて、4 クラス分類で F 値 : 97.5%、8 クラス分類で F 値 : 91.4% の精度を達成した。

Strikes-Thrusts Activity Recognition Using IMUs Towards the Realization of Kendo Skill Support System

TORIGOE YOHEI¹ TAKATA MASASHI¹ NAKAMURA YUGO^{1,2} FUJIMOTO MANATO¹
ARAKAWA YUTAKA^{1,3} YASUMOTO KEIICHI¹

1. はじめに

近年、スポーツ分野における情報技術の活用が急速に進んでいる。これは、試合内容や練習中のパフォーマンスを情報技術を用いて詳細に分析し、フィードバックを行うことにより、競技者のパフォーマンスの向上やトレーニングプロセスの強化が期待できるためである [1]。バスケットボールやクライミングでは、3 軸の加速度計とジャイロ計を備えた慣性計測装置 (Inertial Measurement Unit : 以下、IMU) を手首に装着し、運動中の行動を分析する研究が取り組まれている [2], [3]。

我々も、これまで超小型マルチセンサボードである Sen-

Stick[4] 上の IMU を活用し、基本的なスポーツ行動である自重トレーニングを対象とした行動認識および運動サポートの研究を行ってきた [5]。その結果、IMU を手首と腰に装着すれば、高精度に種々の自重トレーニングを認識することが可能であると確認できた。このように、IMU の活用は、スポーツパフォーマンスの分析において大きな可能性を秘めており、今後 IMU を活用したスポーツパフォーマンスの分析が、これまで注目されていなかった様々なスポーツに展開されることが期待される [6]。また、スマートウォッチをはじめとした、IMU 搭載のウェアラブルデバイスの普及と行動認識技術の発展によって、アマチュアの選手や一般ユーザでも運動サポートを手軽に利用できるようになると考えられる。しかし、様々なスポーツ競技の中でも特に、日本の伝統的なスポーツ競技の一つとして知られている剣道の分野では、RGB-D カメラや特別なセンサを用いた、競技者間のデータの違いに関する議論のみしか行われていない [7], [8]。

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology
² 日本学術振興会特別研究員
JSPS Research Fellowships for Young Scientists
³ JST さきがけ
JST PRESTO

本稿では、日本の伝統的なスポーツ競技である剣道に着目し、IMUを用いたスポーツ動作認識の新しいアプローチ手法を提案する。剣道とは、防具を着けて相対した競技者が、竹刀で定められた部位を打突し合い、勝敗を競う格技の一種である。その打突部位として、「面」、「突き」、「胴」、「小手」の4つの部位が存在する。打突動作において、気剣体の一致と呼ばれる、ポイントを獲得可能な有効打突として認められる基準が存在し、「充実した氣勢」、「正しい竹刀の動き」、「正しい体捌き」の3つの調和が重要とされている。したがって、剣道の技術上達には正しい打突動作の習得が必要である。正しい打突動作を習得するための稽古として最も象徴的な方法は「素振り」である。素振りは正しい打突動作の感覚を身体に染み込ませる効果があり、自分ひとりの感覚で行うのではなく、指導者や他の競技者に意見を求め、客観的な情報を基に補正していくことが好ましい。しかし、実際の稽古では、1人の指導者が複数人の競技者を指導することから、各競技者が打突動作ごとに十分な指導を受けることが難しい。これは、練習効率及びモチベーションの低下や、間違ったフォームで素振り行うことによる怪我を引き起こす可能性がある。

これらの問題を解決するため、本研究の最終目標として、着脱可能なIMUを用いて剣道練習の効率及びパフォーマンスを向上させることで、競技者が単独でも効果的な稽古を可能とする剣道上達支援システムの実現を目指す。本稿では、その第一段階として、打突動作の自動認識に取り組む。具体的には、6人の被験者を対象に、右手首、腰、右足首、竹刀鐔、竹刀先革に取り付けられたSenStick上のIMUから加速度及びジャイロスコープのデータを収集した。対象とする打突動作は、一般的な「面」、「突き」、「胴」、「小手」の4種類と、打突箇所を左右を加えた計8種類とする。6人の被験者から収集されたデータセット(1,440秒)から打突動作の分類モデルを作成した。機械学習アルゴリズムとしてRandom Forest(RF)を用い、個人のデータでのみで学習した結果、右手首のデータのみで、4クラス分類でF値:90.0%、8クラス分類でF値:82.6%の精度で分類できることを確認した。また、腰、右足首のデータを追加することで、4クラス分類で97.5%、8クラス分類で91.4%を達成した。さらに、分類モデルの汎化性能を確認するため、Leave-one-person-out Cross-Validationによる評価を行った結果、4クラス分類において、右手首と竹刀鐔の組み合わせでF値:77.5%であった。

本稿の構成は以下の通りである。第2章で情報技術を活用したスポーツ支援に関する関連研究について述べる。第3章で提案する剣道上達支援システムの全体像について述べた後、IMUを用いた打突動作分類手法を述べる。第4章で評価実験について述べ、最後に第5章で本稿の結論および今後の課題について述べる。

2. 関連研究

本章では、情報技術を活用したスポーツ支援に関する関連研究について述べる。情報技術を活用したスポーツバイオメカニクスは、スポーツ動作の分析とモニタリングシステムに最適なツールを提供する[1]。そのアプローチに使用可能な手法が過去の研究によっていくつか提案されている。これらの多くは、(1)カメラによってスポーツ中のモーションを撮影した映像を分析する手法、(2)IMUを身体部位に装着し、取得されるセンサデータを分析する手法の2つに分けられる。

2.1 カメラベース

カメラを用いる分析手法は、身体に何も装着する必要がないため、競技者は違和感なく計測を行うことが可能である。また、モーショントラッキングによるスポーツ分析は最も頻繁に使用される手法の1つである。さらに、高速運動を伴うスポーツの動作計測への利用が試みられている光学式モーションキャプチャシステム[9]やデジタルビデオカメラを用いたDLT(Direct Linear Transformation Method)法[10]なども存在し、これらのモーションキャプチャシステムはより正確な測定を必要とするアプリケーションで頻繁に使用されている。その反面、システムが大規模かつ高コストとなり、計測範囲も限定され、死角などの詳細な部分は計測できない問題がある。

2.2 センサベース

IMUを用いる分析手法は、身体や競技用具にIMUを装着するなどして、スポーツ中の動作を計測、分析を行う。得られた情報を基に、競技者に対して効果的なフィードバックを与えることで、試合中の戦術に利用したり、効率的な練習が行えるように支援するといった研究が多く行われている。Blankらは卓球ラケットにIMUを取り付け、アマチュア選手とプロ選手10人から収集したデータを基に、8種類の基本ストロークを認識した[11]。Kosmallaらは、両手首に装着したIMUを活用して、クライミングのルートを自動的に認識するシステムを提案した[3]。Jamesらは、先端に加速度センサが搭載された木刀を用いて、剣道の最も基本的な打突動作である正面を行ったときの木刀のスイング特性を解析した[12]。その結果、初級者と熟練者との間でスイングの特性が異なることを定量的に評価可能であると報告している。しかし、計測されたのは正面だけであり、その他の打突動作の評価は行われていない。また、手首の動きや踏み込みといった動作は計測されていない。




図 1 各打突動作

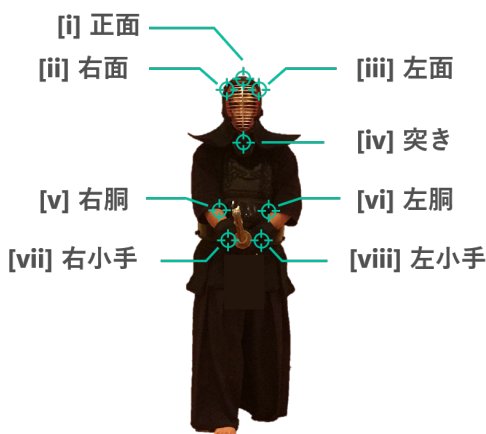


図 2 分類ラベル



図 4 SenStick の装着位置




図 3 SenStick

3. 打突動作の分類

本章では、IMU を活用し、剣道の練習効率及び、選手のパフォーマンス向上を目的とした打突動作の自動分類について述べる。

3.1 概要

本研究の最終目標として、スマートウォッチなどに搭載されている IMU を用いて、素振り中における競技者の打突動作を認識し、動作毎に正しい打突動作へ改善するためのフィードバックを競技者に与えることが可能な剣道上達支援システムの実現を目標としている。本稿では、剣道上達支援システムの実現に向けた第一段階として、素振り中における打突動作の認識に注力する。

3.2 対象とする打突動作

図 1 に示すように、本研究において分類対象とする基本的な打突動作は以下の 4 種類である。

- 面

竹刀で頭部を打つ打突のことで、最も基本的な打突動作である。基本は頭部上方を打つ正面打ちが用いられるが、面の側面左右 45° を打つ左右面も存在する。

- 突き

相手の喉元にある突き垂を剣先（竹刀の先の部分）で突く打突動作である。

- 胴

相手の胴の部分（脇）を打つ打突動作である。剣道では原則右胴が主流であるが、左胴を打突する方法も存在する。


- 小手

小手は相手のどちらか一方の手首を竹刀で打つ打突動作である。


本研究では、図 2 に示す打突箇所に対し、[i]～[viii] までのラベル付けを行った。これらの分類ラベルは次節以降でも使用される。

3.3 使用センサデバイスと装着位置

本稿では、我々が開発した SenStick[4]（図 3）を打突



(a) 加速度データ



(b) ジャイロデータ

図 5 右手首に装着した IMU のデータ波形

動作を分類するためのセンサデバイスとして使用する。SenStick には、8 種類の MEMS センサ（加速度、ジャイロスコプ、磁気、温度、湿度、圧力、照度、UV）が装備されており、最大 100Hz で記録できる。また、Bluetooth Low Energy (BLE) によってデータを収集することもできる。本稿では、SenStick に搭載されている加速度センサ、ジャイロスコプの 6 軸センサを使用して打突動作を分類する。打突動作時は高速運動であり、その動きを正確に測定する必要があると考えるため、6 軸センサのサンプリングレートを 100Hz に設定する。なお、本稿では、SenStick の装着位置として図 4 に示すように、競技者の装着時の負担及び打突動作への影響が少ないと考えられる (1) 右手首、(2) 腰、(3) 右足首とする。これらに加えて、(4) 竹刀鐔と (5) 竹刀先革にも装着する。一例として、図 5 に SenStick によって計測された (1) 右手首における加速度とジャイロ波形を示す。図 5 より SenStick から得られる加速度とジャイロデータは、各打突動作時に生成される信号パターンを確実に捕らえられていることが確認できる。

3.4 特徴選択

SenStick から 100Hz のサンプリングレートでそれぞれ取得された 3 軸加速度及び 3 軸ジャイロデータから特徴量を計算する。各センサについて、合成値を式 (1) を用いて計算する。3 秒の時間窓で区切られたデータは、事前調査において各打突動作の特徴を表すのに十分なサンプルを含むことが確認できたため、本稿では時間窓を 3 秒に設定した。3 秒の時間窓で分けられた加速度とジャイロのデータから表 1 に示す特徴量を抽出する。

表 1 抽出した特徴量


ドメイン	特徴量
時間ドメイン	最大値, 最小値, 平均値, 標準偏差, 合計, 範囲 (最大値-最小値), 分散, 中央値絶対偏差, 四分位範囲, 尖度, 二乗平均平方根, 相関
周波数ドメイン	最大マグニチュード, 総エネルギー, 最大マグニチュード位置, エントロピー, 尖度, 歪度

表 2 被験者データ


被験者	年齢	体重 (kg)	身長 (cm)	性別	経験年数 (年)
A	22	45.0	157	女	0
B	23	55.4	160	男	0
C	23	70.0	171	男	0
D	23	82.0	174	男	2
E	23	62.0	177	男	1
F	23	82.0	175	男	0

$$composite = \sqrt{(x^2 + y^2 + z^2)} \quad (1)$$

時間ドメインからは、最大値、最小値、平均値、標準偏差、合計、範囲 (最大値-最小値)、分散、中央値絶対偏差、四分位範囲、尖度、二乗平均平方根、相関の 13 種類の特徴量を抽出する。周波数ドメインからは、最大マグニチュード、総エネルギー、最大マグニチュード位置、エントロピー、尖度、歪度の 6 種類の特徴量を抽出する。これらの特徴量を選択する理由として、主に慣性データを用いたコンテキスト推定に関する先行研究から有効性が示されているためである [13], [14]。



(a) 4 クラス分類



(b) 8 クラス分類

図 6 打突動作分類結果

4. 評価実験

本章では、(1) 右手首、(2) 腰、(3) 右足首、(4) 竹刀鐔、(5) 竹刀先革に装着された SenStick 上の IMU から収集される加速度とジャイロデータを基に、4 種類の機械学習手法の性能比較及び SenStick 装着位置別による種目認識の評価結果について述べる。

4.1 実験準備

本実験では、打突動作を行う前に、経験者による軽い指導を受けた後、各打突動作に対して静止状態をとってから 10 セットずつ素振りを行う。被験者は 6 名とし (表 2)、全体として 1,440 秒 (480 試行) の打突動作を記録している。被験者のセンサデータを追跡することに加え、全ての打突動作は映像として記録され、映像に基づいて手作業でセグメント化された。記録されたセンサデータから抽出される特徴量に基づき、機械学習を用いて打突動作の認識を行う。分類ラベルは 4 つ ([i, ii, iii], [iv], [v, vi], [vii, viii]), 8 つ ([i], [ii], [iii], [iv], [v], [vi], [vii], [viii]) として定める。学習モデルを構築するための Python 機械学習ライブラリ scikit-learn[15] を使用する。scikit-learn は多数の機械学習アルゴリズムに基づく分類器を実装しており、提案手法では、代表的な機械学習アルゴリズムである、Random

Forest (RF), Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Neural Network (NN) の 4 つを用いる。

4.2 実験結果

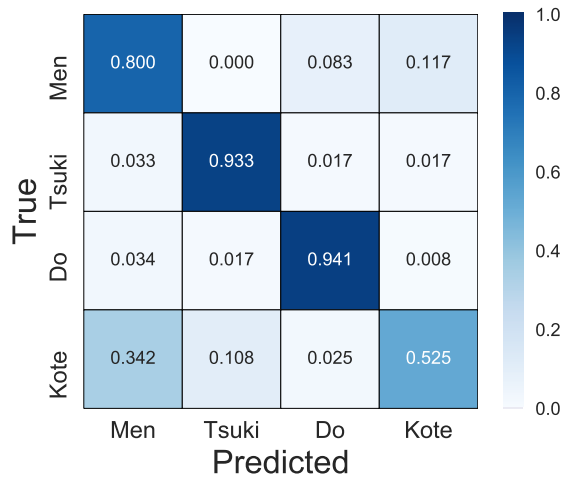
図 6 に 4 種類の異なる機械学習アルゴリズム (RF, SVM, KNN, NN) を用いて、個人のみで学習した打突動作の分類精度結果 (F 値) の 6 人の平均値を示す。横軸はセンサの組み合わせを示し、各色は機械学習アルゴリズムを示す。

4.2.1 異なる機械学習アルゴリズムによる分類結果

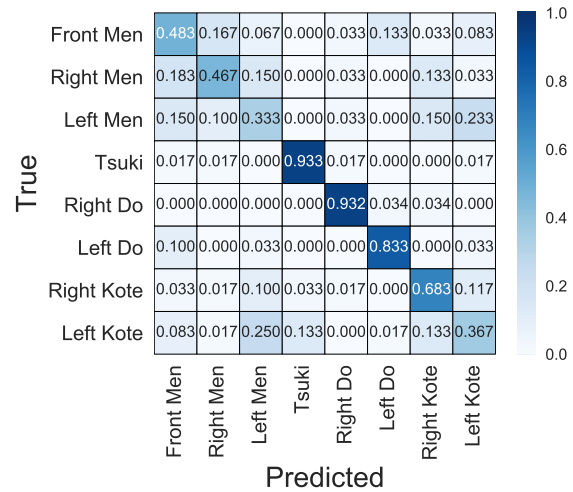
本項では、異なる機械学習アルゴリズムによる分類結果を比較する。図 6 (a) において、最も認識精度が高いものは、機械学習アルゴリズムに Random Forest (RF) を用いた場合であり、F 値: 94.0%であった。対比的に、最も認識精度が低いものは、機械学習アルゴリズムに CNN を用いた場合であり、F 値: 67.9%であった。この傾向は図 6 (b) に示す 8 つの分類ラベルにおいても同様の結果が見られた。理由としては、Random Forest (RF) は多数の決定木を生成し、それら複数の決定木から多数決によって分類するアルゴリズムであることが挙げられる。また、決定木を弱学習機としているため、Random Forest (RF) はノイズに対して強いという特徴があることも要因であると考えられる。よって、提案手法では機械学習アルゴリズムとして

表 3 Leave-one-person-out Cross-Validation の分類精度結果 (F 値)
 (RW=右手首, W=腰, RA=右足首, ST=竹刀鍔, SS=竹刀先革)

Label	RW	RW+W	RW+RA	RW+ST	RW+SS	RW+W+RA	RW+ST+SS	ST	SS	ST+SS
4 Classification	65.3%	59.5%	62.8%	68.9%	77.5%	52.0%	70.6%	67.0%	61.2%	71.6%
8 Classification	42.4%	39.2%	36.5%	59.0%	56.5%	24.6%	61.0%	62.2%	45.9%	52.4%



(a) 4 クラス分類



(b) 8 クラス分類

図 7 Leave-one-person-out Cross-Validation における混同行列結果

Random Forest (RF) が有効であると確認できた。

4.2.2 IMU 装着位置別での分類結果

本項では IMU の装着位置別の分類精度について比較する。我々の最終目標は手首に装着された IMU のみで剣道競技者を支援することであるため、身体に装着された IMU と竹刀に装着された IMU が同じ精度で打突動作を認識できる必要がある。そこで、はじめに竹刀に装着された IMU と右手首に装着された IMU の分類精度の比較を行った。竹刀に装着された IMU のセンサデータを用いて打突分類を行った場合、竹刀鍔は 4 クラス分類で F 値：92.5%，8 クラス分類で F 値：85.6%，竹刀先革は 4 クラス分類で F 値：93.9%，8 クラス分類で F 値：83.7% を達成した。次に、右手首に装着された IMU のセンサデータを用いて打突動作分類を行った場合、4 クラス分類で F 値：90.0%，8 クラス分類で F 値：82.6% を達成した。したがって、手首に装着された IMU は、竹刀に装着された IMU と概ね同等の精度で打突動作を分類可能であると確認できた。

さらに、右手首に装着された IMU のセンサデータに対し、その他の位置に装着された IMU のセンサデータを組み合わせた場合における打突動作の分類精度を検証した。その結果、IMU を 2 つの装着した場合の組み合わせとして、最も認識精度が高いのは右手首+右足首の組み合わせで、4 クラス分類で F 値：94.6%，8 クラス分類で F 値：88.9% を達成した。また、IMU を 3 つ装着した場合の組み合わせとして、最も認識精度が高いのは右手首+腰+右足首の組み合わせで、4 クラス分類で F 値：97.5%，8 クラス

分類で F 値：91.4% を達成した。したがって、手首のセンサデータに加えて、他の位置のセンサデータを組み合わせた場合、さらに分類精度が向上することを確認した。

4.2.3 Leave-one-person-out Cross-Validation による分類結果

本項では、分類モデルの汎化性能を確認するため、全被験者から 1 人を取り出して評価データとし、残りを学習データとすることで全被験者が 1 回は評価となるように検定を繰り返す Leave-one-person-out Cross-Validation により各打突動作の分類精度 (F 値) を評価する。機械学習アルゴリズムは 4.2.1 項で最も認識精度が高かった Random Forest (RF) を用いた。また、パラメータはグリッドサーチを行い最適化した。表 3 に認識結果を示す。4 クラス分類において、最も認識精度が高いのは右手首+竹刀鍔の組み合わせで、F 値：77.5% であった。図 7 (a) に混同行列を示す。この結果は、4.2.2 項と同様の組み合わせ結果となった。一方、8 クラス分類において、最も認識精度が高いのは竹刀鍔のみの場合で、F 値：62.2% であった。図 7 (b) に混同行列を示す。結論として、個人のみデータを学習すれば、高精度に打突動作の認識可能である。しかし、打突動作に個人差があったことから Leave-one-person-out Cross-Validation の分類精度は良い結果が得られなかった。原因として、被験者に剣道未経験者が多く含まれていたことで、個人差が生まれたと考えられる。今後は、剣道経験者のデータを中心に収集し、提案手法の改良に努めていく予定である。

5. 結論

本稿では、日本の伝統的なスポーツ競技の一つである剣道に着目し、スマートウォッチなどに搭載されているIMUを用いて、素振り中における競技者の打突動作を認識する手法を新たに提案した。提案手法の有効性を示すため、6人の被験者を対象に、右手首、腰、右足首、竹刀鏢、竹刀先革に取り付けられたSenStick上のIMUから得られる加速度、ジャイロデータのみを使って、打突動作の分類を行なった。対象とする打突動作は、剣道において最も一般的な「面」、「突き」、「胴」、「小手」の4種類と、打突箇所を左右を加えた8種類である。機械学習アルゴリズムとしてRandom Forest (RF)を用い、個人のデータでのみで学習した結果、右手首のデータみで、4クラス分類でF値: 90.0%、8クラス分類でF値: 82.6%の精度で分類することに成功した。また、腰、右足首のデータを追加することで、4クラス分類で97.5%、8クラス分類で91.4%を達成した。さらに、分類モデルの汎化性能を確認するため、Leave-one-person-out Cross-Validationによる評価を行った結果、4クラス分類において、右手首+竹刀鏢の組み合わせでF値: 77.5%であった。結論として、個人のデータを学習すれば、高精度に打突動作の認識が可能である一方、動作に個人差があったことからLeave-one-person-out Cross-Validationの分類は良い結果が得られなかった。原因として、被験者に剣道未経験者が多く含まれていたことで、打突動作に個人差が生まれたと考えられる。今後は、剣道経験者のデータを収集し、被験者数を増加させる。また、提案手法の改良に努め、技能上達に向けたフィードバック機構の実装を行い、剣道上達支援システムの実現を目指す。

謝辞 本研究の一部は、JST さきがけ及びACT-Iの支援により実施された。ここに謝意を示す。

参考文献

- [1] McGinnis, P. M.: *Biomechanics of sport and exercise*, Human Kinetics (2013).
- [2] Bai, L., Efstratiou, C. and Ang, C. S.: weSport: Utilising wrist-band sensing to detect player activities in basketball games, *Pervasive Computing and Communication Workshops (PerCom Workshops), 2016 IEEE International Conference on*, IEEE, pp. 1–6 (2016).
- [3] Kosmalla, F., Daiber, F. and Krüger, A.: ClimbSense: Automatic climbing route recognition using wrist-worn inertia measurement units, *Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*, ACM, pp. 2033–2042 (2015).
- [4] Nakamura, Y., Arakawa, Y., Kanehira, T., Fujiwara, M. and Yasumoto, K.: SenStick: Comprehensive Sensing Platform with an Ultra Tiny All-In-One Sensor Board for IoT Research, *Journal of Sensors*, Vol. 2017 (2017).
- [5] Takata, M., Fujimoto, M., Yasumoto, K., Nakamura, Y. and Arakawa, Y.: Investigating the Capitalize Effect of Sensor Position for Training Type Recognition in a Body Weight Training Support System, *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, ACM, pp. 1404–1408 (2018).
- [6] James, D. A.: The application of inertial sensors in elite sports monitoring, *The engineering of sport 6*, Springer, pp. 289–294 (2006).
- [7] Tejero-de Pablos, A., Nakashima, Y., Sato, T. and Yokoya, N.: Human action recognition-based video summarization for RGB-D personal sports video, *2016 IEEE International Conference on Multimedia and Expo (ICME)*, IEEE, pp. 1–6 (2016).
- [8] Jeong, K., Fuss, F. K., Fuernschuss, B. and Weizman, Y.: Development of a smart Kendo sword and assessment of grip pressure of Kamai stance and Kote cut, *Procedia Engineering*, Vol. 112, pp. 231–236 (2015).
- [9] Moeslund, T. B. and Granum, E.: A survey of computer vision-based human motion capture, *Computer vision and image understanding*, Vol. 81, No. 3, pp. 231–268 (2001).
- [10] Abdel-Aziz, Y.: Direct linear transformation from comparator coordinates into object space in close-range photogrammetry, *Proceedings of the ASP Symposium on Close-Range Photogrammetry, 1971*, American Society of Photogrammetry, pp. 1–18 (1971).
- [11] Blank, P., Hoßbach, J., Schuldhaus, D. and Eskofier, B. M.: Sensor-based stroke detection and stroke type classification in table tennis, *Proceedings of the 2015 ACM International Symposium on Wearable Computers*, ACM, pp. 93–100 (2015).
- [12] James, D., Uroda, W. and Gibson, T.: Dynamics of a swing: A study of classical Japanese swordsmanship using accelerometers, *The impact of technology on sport*, pp. 355–60 (2005).
- [13] Nakamura, Y., Umetsu, Y., Talusan, J. P., Yasumoto, K., Sasaki, W., Takata, M. and Arakawa, Y.: Multi-stage activity inference for locomotion and transportation analytics of mobile users, *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*, ACM, pp. 1579–1588 (2018).
- [14] Pernek, I., Hummel, K. A. and Kokol, P.: Exercise repetition detection for resistance training based on smartphones, *Personal and ubiquitous computing*, Vol. 17, No. 4, pp. 771–782 (2013).
- [15] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. et al.: Scikit-learn: Machine learning in Python, *Journal of machine learning research*, Vol. 12, No. Oct, pp. 2825–2830 (2011).