

ディープラーニングを用いたバレーボールの動作認識の検討

中川 樹[†] 樋口 好彦[†] 大野 拓摩[†] 重永 貴博[†] 中井 一文[†] 江崎 修央[†]

[†]鳥羽商船高等専門学校

1 はじめに

近年、スポーツにおける IT の活用が目目され、試合分析や指導に用いられている。日本のバレーボール競技においてもタブレット端末とスコアによる分析ソフトを用いることで戦術を的確に切り換え、指示を明確に伝えている。しかし、このような分析には入力に時間や人手が掛かる上、動画と各選手のスコアによる分析を行うだけでは、得点率の高い選手や選手同士のコンビネーションの調子などの情報しか得られない。1 プレー中の選手の位置、次の動作の準備など具体的な情報はすぐに可視化できず、選手側と指導者側のイメージが一致しない。選手の技術向上には、より客観的な分析を可能にしなければならないと考えられる。

バレーボール競技においては、コート上で選手が移動しながらボールを追い、各ポジションの役割をこなす。選手はスパイクやトス、レシーブ、ブロックなどのプレーや、ジャンプやダッシュなど多種に渡る動作を行う。動作の質や速さ、移動量などで今後の試合展開に大きな影響を与える。

本研究ではバレーボールの試合動画に対して AI による動作分析を行い、選手の動作データを数値や文字に起こすことで可視化し、選手側と指導者側のイメージ一致を容易にすることを目的とする。これにより、部活動などにおける技術指導の質が向上することを想定している。

2 関連研究

バレーボール競技のレシーブにおいて、熟達のための要因は複数存在する。熟達するには、指導者が選手の各動作始動タイミングの指摘をすることや、レシーブ位置までのステップ動作にも着目して指導を行う必要がある[1]。ボールの動きや相手選手の動作に対して、選手が予備動作を行うことで次のプレーに繋がりがやすく、また相手のフェイントなど予期せぬプレーにも反応しやすくなる。予備動作を行うことで、次

の攻撃や選手間のコンビネーションの上達にも繋がり、チーム全体の熟達に貢献する。

本研究においても、動作始動のタイミングや選手の予備動作の有無、構えなどに注目し指導や試合分析を行う予定である。

3 学習モデルの構築

今回、動作認識には物体検出アルゴリズムである YOLO[2]を用いた。YOLO の学習には検出した物体が写っている画像データと、その物体のクラス名、学習させたい範囲の座標が入力されているテキストデータが必要である。スパイク、アンダーハンドでのプレー、オーバーハンドでのプレー、ブロックといった 4 クラスの動作を行っている画像を用意した。

画像を各クラス約 1500 枚前後用意し合計約 6000 枚とした。図1に示す各クラスの与えた座標データ例は表1のようになっている。




図1 学習させる画像データの例

表1 動作種別の学習に用いる座標データの例

	クラス 番号	中心の X座標	中心の Y座標	中心座標 からの幅	中心座標 からの高さ
スパイク	0	0.53159	0.43585	0.08953	0.31459
アンダー ハンド	1	0.41857	0.42960	0.02905	0.27777
オーバー ハンド	2	0.85526	0.44521	0.07601	0.16773
ブロック	3	0.45233	0.64324	0.03213	0.29084

4 検出実験

4.1 実験概要

本研究ではバレーボール競技の試合撮影を行い、その試合動画を基に YOLO で学習させるためのデータセットを作成し、4 種類の動作を学習させた。未知データであるバレーボール競技 1 セッ

A Study on Motion Recognition of Volleyball Using Deep Learning

[†]Yoshihiko Higuchi [†]Itsuki NAKAGAWA [†]Takuma Ono

[†]Takahiro SHIGENAGA [†]Kazufumi NAKAI [†]Nobuo EZAKI

[†]National Institute of Technology, Toba College

ト分の試合動画でプレーしている選手に対し、動作学習モデルでの動作検出を行った。

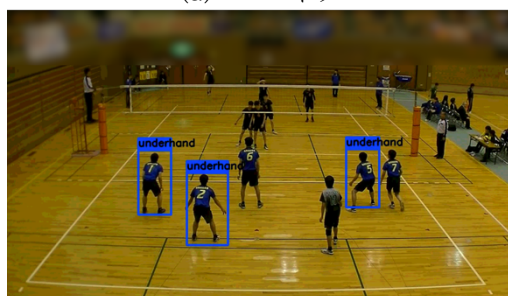
4.1 検出結果と考察

動画からの動作検出において各動作の検出成功フレームを図2に示す。


図2(a)～(d)中の枠線で囲まれている部分が検出できた。今回構築した学習モデルでは、選手の体勢が大きく崩れているプレーや、プレー中の選手の体の向きに対応できている。その様な体勢でのプレーを検出するため、学習データに多様な体勢でのプレーを組み込んだ。




(a) スパイク



(b) アンダーハンド



(c) オーバーハンド



(d) ブロック

図2 各動作の検出結果

表2 各選手の動作数と学習モデルによる検出数

	選手1	選手2	選手3	選手4	選手5	選手6
動作数	31	47	18	18	23	33
検出数	28	44	15	16	20	32

動作検出結果を表2に示す。動作数は実際に選手が行った各動作を人間が計測した回数、検出数は選手が行った各動作を学習モデルが検出した動作回数である。動作数、検出数共にスパイク、アンダーハンドでのプレー、オーバーハンドでのプレー、ブロックの4つの動作数の合計となっている。

今回の実験では、学習モデルでの動作検出が出来ていても動作予測の確率が50%以下であるもの、動作検出が1フレーム分のみの結果や極端に短い動作と判断された場合のものは検出数に含まれない。

検出結果の内、正例で正と検出されたものをTP、負と検出されたものをTNとし、負例で正と検出されたものをFP、負と検出されたものをFNとして検出性能の指標を式(1)に示す。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

表2の結果に(1)式を適用して学習モデルのOverall Accuracy(全体の精度)を求める。Overall Accuracyは0.91であった。この結果から学習の際の画像の種類、また反復学習を適正のタイミングで終わられたことがOverall Accuracyを高めた要因だと考えられる。

5 まとめと今後の課題

今後、動作認識だけでなく、動作認識と数字認識を組み合わせることで各選手の背番号を識別し、動作の解析を行うモデルを構築していく。

構築したAIを、バレーボール部での試合分析や、技術指導に活用していく。得られたフィードバックから、誰でも手軽にプロのデータアナリストと同等の分析結果を手に入れられるシステムを目指す。

参考文献

- [1] 浅井憲一, 大神訓章. バレーボールの左右移動にいける熟練の要因に関する運動的考察. 山形大学紀要 教育科学. 2001, vol. 12, p. 47-58.
- [2] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi. You Only Look Once: Unified, Real-Time Object Detection. arXiv:1506.02640[cs.CV].