

アメリカンフットボールの可視化と深層学習によるパスプレーのマッチアップ分析に関する研究

Research for Visualization System and Match-up Analysis of Pass play in American Football

○田中ちひろ¹, 山本雄平², 姜文淵², 中村健二³, 田中成典², 林勲²

○Chihiro Tanaka¹, Yuhei Yamamoto², Wenyuan Jiang², Kenji Nakamura³, Shigenori Tanaka², Isao Hayashi²

¹ 関西大学大学院 ² 関西大学 ³ 大阪経済大学

¹Kansai University Graduate School ²Kansai University ³Osaka University of Economics

Abstract: In our country, policies regarding sports are actively advanced towards the Tokyo 2020 Olympic Games. One of those policies, "Sports x ICT" considers effective methods of utilizing ICT (Information and Communication Technology), such as development of measurement instruments, measurement and visualization of data, and proposals for new services in the field of sports. Against this backdrop, we have been developing the visualization system for American football games using terminal devices included GNSS and acceleration sensor. Using that system, it is confirmed that the effective information which are the individual condition and the motion analysis of american football players against not only players but also the college football leaders can be grasped. But, in the our existing research, we could not realize the strategy for analyzing games selected for play calls depending on circumstances, to make a prediction of successful ratio, and so on. Then, in this paper, we aim to analyze the match-up for offence and defense players related to pass plays using deep learning. Reasoning the success rate of pass plays, it is capable to provide the new awareness for American football strategies to the manager and coaches.

1. はじめに

我が国では、2020年の東京オリンピック・パラリンピックに向けて、最新のトレーニング手法の導入や競技レベルの向上に関する政策[1]が推進されている。この背景の下、計測機器を用いた計測データの可視化および分析システムの開発と活用が促進されている。しかし、これらのシステムは画一的な分析方法がないことから普及が進んでいない。また、分析の対象もプロスポーツに限定されており、カレッジスポーツでの利用が促進されているとはいえない。そこで、本研究では、チームスポーツの中でも複雑かつ論理的な戦術を要し、選手の役割が明確であるカレッジスポーツのアメリカンフットボールに着目する。その中でも戦術上で重要なパスプレーに着目し、GNSSの計測データを可視化するシステム[2]で可視化した軌跡画像を用いて、深層学習による戦術分析を試みる。深層学習を用いて、選手の軌跡画像データにより投球から捕球（マッチアップ）の成否を判定することで、実際に指導者が求めている情報であるQB（投球者）の位置とパスのタイミング、WR（捕球者）のコース取り、DB（阻止者）の反応動作などが分析できるかを検証する。

2. 研究概要

2.1 入力データ

深層学習による分析過程を図1に示す。入力データは、プレーの計測データ、プレーの状況データとパスの成否のラベルである。データ計測では、GPSports[3]によるGNSSデータ（以下、プレーの計測データ）の計測と、プレーに関する情報（以下、プレーの状況データ）を目視で記録する。プレーの

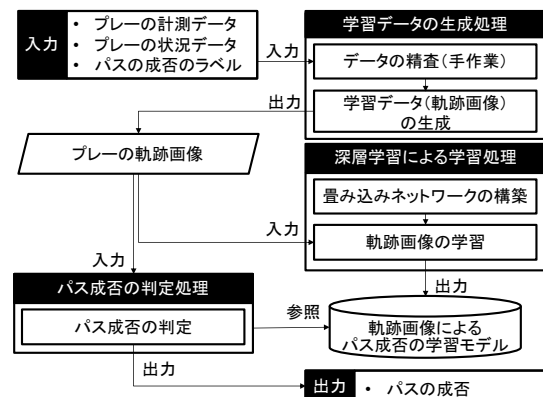


図1 深層学習による分析過程

状況データは、1プレーに出場した選手の一覧、プレーの開始時刻、QBの投球時刻、WRまたはDBの捕球時刻、プレーの終了時刻を手作業で記録した。

2.2 深層学習によるマッチアップ分析

軌跡画像の生成は、2.1で示した手順でプレーの状況データと撮影していた動画とを照らし合わせ、プレーの計測データから1プレーごとの軌跡画像を出力する。練習時のプレーでは、マッチアップ解析に無関係の選手が存在するため、プレーごとに記録した出場選手のデータのみを選別して可視化した。記録日時は、2017年2月12日からの計7日間である。深層学習には、畳み込みニューラルネットワーク(CNN: Convolutional neural network)の手書き文字認識を用いる。本研究では、Google社が公開しているTensorFlowで実装を行う。選定理由は、汎用性が高く、チュートリアルサンプルが多く揃っているためである。

3. 実証実験

計測データから生成した軌跡画像を学習用データと評価用データに分割し、学習用データを深層学習へ入力する。そして、選手の軌跡画像を学習して、評価用データによりマッチアップの精度を評価した。学習用データには、マッチアップのパス成功事例 40 件と失敗事例 28 件の合計 68 件を用い、そのうち各 7 件の合計 14 件を評価用データとした。なお、パスの成否は、成功・失敗以外に成功するはずが失敗したパスなどを含め 4 通りの結果が考えられる。本実験では、CNN による出力クラスをパス成功・失敗の 2 通りとしたが、これらの 4 通りの結果を加味し、F 値で 0.600 を目標精度とする。

まず、学習用データを用いて、軌跡画像から抽出すべき特性項目を議論した。具体的には、学習データの成功・失敗事例の 2 属性(各同数件数/全件数)、画質の 2 属性(カラー/白黒)、拡張の有無の 2 属性(データの回転や反転による拡張:有/無)から、入力属性として有用な特性を議論した。実験では、「データ件数が同数」、「カラー画質」、「データの回転有」と設定して描画した画像を規定値とした。表 1 の結果から、最も精度が高い属性として、成功・失敗事例の各件数から同数を抽出し、カラー画像を回転・反転により拡張させた場合となった。特に、カラー画質を考慮した属性は、F 値の差が 0.325 と大きく、カラー画像とすることで選手やチームの判別が容易となり、画像認識の属性として有用であるといえる。

次に、各描画属性の項目を詳細にみる。各入力属性で 2 条件を設定し、それぞれの精度を比較した。実験では、「フィールド白線を非表示」、「軌跡線幅を 4pt で描画」、「パスタイミング箇所を描画」、「軌跡を 1.3 倍で描画」、「選手の軌跡色を分割して描画」、「画像サイズを 32px×32px で描画」と設定して描画した画像を規定値とした。表 2 の結果から、画像サイズを大きく設定(128px×128px)した場合に精度が最も低下することがわかる。画像サイズが大きくなった場合、背景画像の面積比率が高くなり、軌跡を正しく認識できなかったと考えられる。

表 1 と表 2 の入力属性とその属性項目を用いて、評価用データに深層学習を適用し、マッチアップ分析を行った。図 2 に示す結果から、選手の移動軌跡がともに長い場合や短い場合のプレーでは、正しくパスの成否が認識されているが、選手間の移動距離が異なるパターンでは、パスの成否の判断が困難であることがわかった。この結果から、深層学習において、パスの成否の認識は、選手間の相互距離に依存することがわかる。この結果は、監督やコーチが、選手に対してチームメイトの選手の動きを見てパスを行うように指導する観点と一致している。

4. まとめ

本研究では、GPSports を用いて選手のプレー軌跡を可視化するシステムで軌跡画像に関わる入力属性を検討し、深層学習により選手のパスプレーのマッチアップ分析を行った。今後は、試合中のフォーメーションの分析と精度の向上を目指す。

表 1 各特性項目の精度

特性項目	適合率	再現率	F 値
規定値	0.671	0.670	0.669
データ件数	0.521	0.518	0.499
画質	0.344	0.348	0.344
回転・反転	0.531	0.527	0.510

表 2 各描画項目の精度

描画項目	適合率	再現率	F 値
規定値	0.538	0.536	0.528
白線の有無	0.464	0.464	0.464
軌跡の線幅	0.491	0.491	0.484
パスタイミングの有無	0.450	0.455	0.439
軌跡のスケール	0.410	0.411	0.409
選手の着色	0.479	0.482	0.461
画像サイズ	0.250	0.250	0.333




図 2 マッチアップ分析の結果

参考文献

- [1] スポーツ庁：平成 30 年度競技力向上事業の実施に関する基本方針，<http://www.mext.go.jp/sports/b_menu/houdou/30/03/_icsFiles/afieldfile/2018/03/30/1402903_1.pdf>，(入手 2018.7.9)。
- [2] 山本雄平，田中成典，姜文淵，中村健二，田中ちひろ，清尾直輝：アメリカンフットボールの可視化システムの開発および選手のプレー分析に関する研究，情報処理学会論文誌，情報処理学会，Vol.59, No.5, pp.1334-1350, 2018.
- [3] フォーアシスト社：GPS システム SPI HPU，<http://4assist.co.jp/gpsports/gpsports_top2.html>，(入手 2018.7.9)。

連絡先

田中ちひろ
E-mail: k805182@kansai-u.ac.jp