

# サッカーのプレー種別の分類に関する研究

姜 文淵† 山本雄平‡ 坂本一磨†‡ 中村健二‡‡ 鳴尾丈司††† 田中成典†††  
 松尾龍平†††† 青木大誠†††† 國納健太†††

大阪産業大学工学部† 関西大学環境都市工学部‡ 公立小松大学生産システム科学部††  
 大阪経済大学情報社会学部‡‡ 関西大学先端科学技術推進機構††† 関西大学総合情報学部††††  
 関西大学大学院総合情報学研究所††††

## 1. はじめに

我が国では、大学スポーツ協会（UNIVAS）が設立[1]され、大学スポーツの発展と競技力の向上に力を入れている。その中で、チームの実力向上を図るために、試合映像をプレー種別毎に分類し確認しているが、多大な労力が必要である。そのため、既存研究[2]では、YOLOv4[3]を用いて選手の位置情報からサッカーのセットプレーを分類することを試みている。しかし、シュート、パス、ドリブルに対しては、ボールの位置情報を考慮していないため正確性に課題があった。そこで、本研究では、ボール・選手の位置情報と各選手の所属から、LSTM[4]を用いてそれらを分類する方法を提案する。

## 2. 研究の概要

本研究では、各プレー（図 1）の分類を行う。提案手法（図 2）では、入力データはボール・選手の位置情報と各選手の所属とし、出力データはプレー種別とする。入力データについては、まず、試合映像からそれぞれのプレー種別毎に手動で切り出す。次に、それらの全フレームに対して、ボール・選手にバウンディングボックスを手動で付与する。そして、その底辺の midpoint を位置情報とする。各選手の所属は、攻守に基づいて手動で付与する。提案手法は、1) プレー

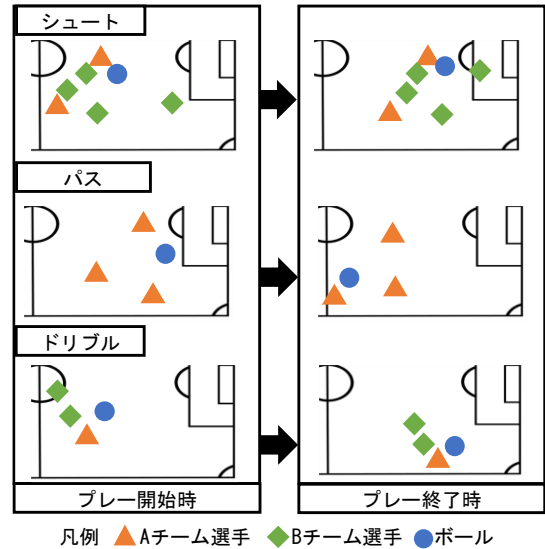


図 1 各プレーのイメージ

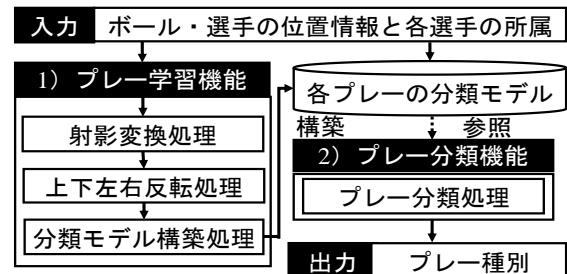


図 2 提案手法の流れ

学習機能と 2) プレー分類機能で構成される。

### 2.1 プレー学習機能

本機能では、各プレーの分類モデルを構築する。まず、射影変換からフィールドを俯瞰した平面図に変換する。次に、上下左右反転処理でデータ拡張を実施する。最後に、LSTMを用いてシュート・パス・ドリブルを分類するモデルを構築する。

### 2.2 プレー分類機能

本機能では、各プレーの分類モデルを用いて、入力データからプレー種別を分類する。各プレーの分類モデルを参照し、各プレーがどれに該当するかの確率を算出する。そして、最も確率が高いプレーをプレー種別とする。

## Research for Classifying Soccer Play Types

- † Wenyuan Jiang  
Faculty of Engineering, Osaka Sangyo University
- ‡ Yuhei Yamamoto  
Faculty of Environmental and Urban Engineering,  
Kansai University
- †‡ Kazuma Sakamoto  
Faculty of Production Systems Engineering and  
Sciences, Komatsu University
- ‡‡ Kenji Nakamura  
Faculty of Information Technology and Social Sciences,  
Osaka University of Economics
- ††† Takeshi Naruo  
Organization for Research and Development of  
Innovative Science and Technology, Kansai University
- †††† Shigenori Tanaka and Kenta Kokuno  
Faculty of Informatics, Kansai University
- ††††† Ryohei Matsuo and Taisei Aoki  
Graduate School of Infomatics, Kansai University

### 3. 実証実験

本実験では、分類モデルの違いによるプレー分類精度の比較を行い、提案手法の有用性を確認する。

#### 3.1 実験内容

本実験では、分類モデルによる出力結果と正解ラベルを比較することで、提案手法のプレー分類精度を確認する。まず、3クラスの分類モデルを構築し、各プレーを分類する実験（以下、実験1）を行う。次に、シュートはパス、ドリブルと比べるとプレー自体の特性が異なるため、二値分類としてシュートを分類するモデルとドリブルを分類するモデルを構築し、シュートの分類モデルを用いた後、ドリブルの分類モデルを用いることで、各プレーを分類する実験（以下、実験2）を行う。本実験で使用するデータは、3試合分の映像から作成したボール・選手の位置情報と各選手の所属を含む30フレームの時系列データとする。学習データに使用する時系列データ数は9,480件、分類データに使用する時系列データ数は1,656件とする。

#### 3.2 結果と考察

プレー分類精度の比較を表1に示す。実験1のF値は、ドリブルが0.61、パスが0.58、シュートが0.46で、実験2のF値は、ドリブルが0.86、パスが0.95、シュートが0.79となり実験2の方が有用であることが分かった。各プレーの中で、シュート（図3）は、パス、ドリブルとは異なり、ボール・選手の位置情報がフィールドの左右に寄っていることが大半を占めている。また、パスはドリブルと異なり、味方同士が連携するプレーであるため、シュートの分類モデルを用いた後、ドリブルの分類モデルを用いた実験2の場合、各プレーのF値が実験1より高くなった。しかし、実験2にて誤分類したシーン（図4）に着目すると、ボール・選手の位置情報がフィールドの左右に寄る場合にドリブルをシュートと誤分類している。これはプレー分類において、入力データがボール・選手の位置情報と各選手の所属だけでは不十分であることが原因だと考えられる。そのため、ボール・選手の移動速度を考慮することで、さらなるプレー分類精度の向上が期待できる。

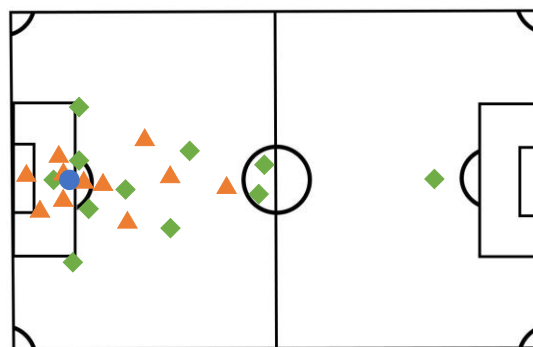
#### 4. おわりに

本研究では、ボール・選手の位置情報と各選手の所属からLSTMを用いて、シュート、パス、ドリブルのプレー分類を行った。今後は、ボール・選手の位置情報と各選手の所属だけではなく、ボール・選手の移動速度を追加することでプレー分類精度の向上を目指す。

表1 プレー分類精度の比較


実験	種類	分類した件数			適合率	再現率	F値
		ト*1	パ*2	シ*3			
1	ドリブル*1	453	124	43	0.52	0.73	0.61
	パス*2	290	370	0	0.59	0.56	0.58
	シュート*3	124	128	124	0.74	0.33	0.46
2	ドリブル*1	588	32	0	0.79	0.95	0.86
	パス*2	32	628	0	0.95	0.95	0.95
	シュート*3	128	0	248	1.00	0.66	0.79

\*1ドリブル \*2パス \*3シュート



凡例 ▲Aチーム選手 ▲Bチーム選手 ●ボール

図3 シュートと正しく分類したシュート



凡例 ▲Aチーム選手 ▲Bチーム選手 ●ボール

図4 シュートと誤って分類したドリブル

#### 参考文献

- [1] 大学スポーツ協会 (UNIVAS) : 設立概要 : スポーツ庁 (オンライン), 入手先 (https://www.mext.go.jp/sports/b\_menu/sports/univas/index.htm) (参照 2024-01-11) .
- [2] 青木大誠, 姜文淵, 山本雄平, 田中ちひろ, 坂本一磨, 中村健二, 田中成典, 鳴尾丈司, 松尾龍平, 肖智蔵 : サッカーにおけるセットプレーの自動抽出に関する研究, 第84回全国大会講演論文集, 情報処理学会, Vol.84, No.1, pp.573-574 (2022) .
- [3] Bochkovskiy, A., Wang, Y. and Liao, M. : YOLOv4 : Optimal Speed and Accuracy of Object Detection, arXiv(online), available from (https://arxiv.org/pdf/2004.10934.pdf) (accessed 2024-01-11).
- [4] Hochreier, S. and Schmidhuber, J. : Long Short-Term Memory, *Neural Computation*, Vol.9, No8, pp.1735-1780 (1997)