

サッカートラッキングデータの時空間的関係を考慮した プレー認識手法の検討

今井 友揮¹ 内山 彰¹ 馬込 卓弥² 東野 輝夫¹

概要: プロサッカーにおいて, 戦術解析への利用や各種メディアへの提供という面から, プレーデータの重要度が年々増加している. 特に試合中に発生した各プレーの種類や成否についての記録付けは, 現状では専門の記録者が試合映像を確認しながら人手で行っている. しかし, このような記録作業は時間的な負担が大きいという課題がある. そこで本研究では, 試合中に発生したプレーの種類を自動で認識するための手法を提案する. 提案手法では, 各選手とボールの移動軌跡を表したトラッキングデータを解析し, ボールの移動軌跡に着目することで, プレーが発生したタイミングを検出する. 次に, 検出したタイミングにおいて, 注目時点とその過去, 未来における選手とボールの位置関係から特徴量を抽出し, Conditional Random Field (CRF) を用いて機械学習を行うことでプレーの種類を認識する. 本手法の有効性を評価するために, プレー発生タイミング検出とプレー認識それぞれについて, 実際にJリーグで記録されたトラッキングデータを用いて評価実験を行った. その結果, プレー発生タイミング検出手法では適合率 83%, 再現率 85%と高い性能が得られた. 一方, プレー認識手法では, 全体の平均結果として適合率 66%, 再現率 67%となり今後課題が残るものの, 「パス」, 「クロス」, 「キャッチ」など一部のプレーに関しては, 適合率 70%以上, 再現率 80%以上と認識率の高い結果が得られた.

A Study on Play Recognition Using Spatio-Temporal Relationship of Football Tracking Data

TOMOKI IMAI¹ AKIRA UCHIYAMA¹ TAKUYA MAGOME² TERUO HIGASHINO¹

1. はじめに

近年, プロスポーツにおけるプレーデータは情報技術の発展に伴い重要度を増してきている. 例えば, サッカーにおいては試合結果の記録という面から「シュート数」「コーナーキック数」等といったプレー回数が公式記録として各試合ごとに記録されている. 特に, 日本プロサッカーリーグ, 通称Jリーグにおいてはこれらに加えてより詳細なデータを記録し, 戦術分析へ活用することを目的に, 「パス」「ドリブル」「タックル」等といった試合中に発生したあらゆるボールタッチプレーについて, 回数や成否といったデータについても公式に記録を行っている. これらのプレーデータは, 現状では記録者が試合映像を確認しながら一つ一つの発生プレーに対して手動で記録を行っている.

この記録作業には, 熟練した記録者であっても10時間程度を要し, 作業量の負担が大きいという問題点が存在する.

そこで, 本研究ではこのような記録作業の負担軽減を目的として, 試合中に発生したボールタッチプレーの種類を自動で認識する手法の検討を行う. 提案手法では, TRACABと呼ばれるChyronHego社製のカメラシステムを用いて取得したトラッキングデータ(選手とボールの位置データ)を用いる. これらより得られた特徴量に対して, プレーの時間的前後関係および選手とボールの空間的関係を考慮し, 条件付き確率場(Conditional Random Field (CRF))を用いてプレーの自動認識を行う. ボールタッチを伴うプレーでは, 例えば「クロス」の後に「シュート」が起りやすい, というように, プレーの時系列について考慮することが認識には重要であると考えられる.

そこで本手法では, まず, プレーが発生した場合にはボールの軌道が大きく変化するというに着目し, トラッキ

¹ 大阪大学大学院情報科学研究科

² 大阪大学大学院医学系研究科

ングデータ内のどのタイミングでプレーが発生したかについて検出を行う。次に、検出したプレー発生タイミングにおいて得られる特徴量を用いて、CRFにより与えられた特徴量に対して各プレーの事後確率を求める。CRFは機械学習における一つの学習手法であり、系列ラベリング問題に適した識別モデルである。本手法においては、検出されたプレーの時系列に対して、前後関係を考慮しながら事後確率が最大となるプレーを推定する。

実際にJリーグの試合において記録された21試合分のトラッキングデータを用いて実験を行い、プレー発生タイミングの検出とプレー認識についてそれぞれ有効性を評価した。プレー認識の実験では、「パス」、「スルーパス」、「クロス」、「シュート」など全11種類のボールタッチプレーを認識対象とした。結果として、プレー発生タイミング検出手法では適合率83%、再現率85%と高い性能が得られた。一方で、プレー認識手法では全体を平均した結果として、適合率66%、再現率67%が得られ、課題が残る結果となった。しかし、「パス」、「クロス」、「キャッチ」など一部のプレーに関しては、適合率70%以上、再現率80%以上と、認識率の高い結果が得られた。

2. 関連研究

2.1 スポーツプレー認識

スポーツを対象とするプレー認識は、これまでいくつかの研究がなされている。文献[1]では、アメリカンフットボールの試合映像を画像処理することで、オフフェンス、ディフェンス、キックオフ、パント、フィールドゴールといった種類のプレーについて自動でラベリングする手法が提案されている。文献[2]では、アメリカンフットボールにおいてショートパス、ロングパス、パントなど7種類のプレーを認識するために、試合映像から抽出したカメラの動きのパラメータを元に各発生プレーについて推定を行っている。文献[3]では、バスケットボールの試合におけるトラッキングデータを解析し機械学習することで、複数の選手の動きからボールを保持している選手を推定する手法を提案している。ここで、前後の保持選手の情報を特徴量として活用できるCRFを用いることで、より推定精度を向上させるような取り組みを行っている。

2.2 スポーツデータ分析

また、スポーツデータの解析に対する取り組みも複数存在する。文献[4]では、Jリーグの試合で計測されたトラッキングデータ、プレーのラベルおよび中継映像を用いて、ゴールが起こった直前に発生したプレー群に着目し、チャンス、ピンチを作り出した要因を導出する研究を行っている。文献[5]では、トラッキングデータとパスが発生した時刻のリストから、パスの質を「良い、普通、悪い」の三段階に自動で評価する手法を提案している。この文献では、

各選手の移動軌跡を主な特徴量とし、SVMを用いて機械学習を行い分類精度の評価を行っている。

しかし、これらのスポーツ分析では、全て手動でプレーのラベル付けを行う必要があり、分析データの準備に大きな負担がかかる。本研究では、こういった負担を軽減するためのプレー認識手法を提案する。

3. データセット

3.1 トラッキングデータの特徴

本研究において利用するトラッキングデータは、TRACAB[6]と呼ばれるChyronHego社製のカメラシステムを用いて、実際にJリーグの試合で計測されたものである。このシステムは、専用カメラとコンピュータをスタジアムに設置し、現地でリアルタイムにボール、各選手、審判の動きを自動追尾することでデータを取得している。ユニットあたり三台のカメラを含む二つのカメラユニットをスタジアム上部に左右横並びで設置し、片側のカメラユニットは主にピッチ左側、もう片側のカメラユニットは主にピッチ右側を撮影する。そして、左右のカメラユニットがそれぞれ撮影している映像をリアルタイムに合成し、ピッチ全域をとらえた合成映像を得る。この合成映像に対して、画像認識技術を用いることでピッチ上の全選手とボールの移動軌跡を得る[7]。

本トラッキングデータの問題点として、画像認識技術は完全ではなく、特定の状況においてトラッキングデータ内に誤差を含む可能性がある[7]。例えば、選手同士が重なって接触した場合、狭い範囲内に多数の選手が密集した場合、白いボールが白線上に重なった場合、ボールがピッチ外へ出た場合、ボールが上空に高く上がることでカメラの視野角から外れた場合等においては自動追尾が困難となり、その結果予測不能の誤差がトラッキングデータ内に含まれることがデータを解析することによって判明した。

これらの条件のため、プレー発生検出、プレー認識性能の低下は避けられない。そこで、前述のようなトラッキングデータに誤差が生じる条件を自動で検出することで、各プレー発生時刻におけるデータをどれぐらい信頼してよいか定義した信頼度を算出する。そして、本手法により得られる認識結果とその時点における信頼度の組を出力することで、信頼度がある一定値未満の場合における結果は信頼してはいけないとする、といった方針を取ることを対策として考えている。

3.2 トラッキングデータの詳細

トラッキングデータには、ピッチに存在する出場選手全22人(チームA:11人 チームB:11人)とボールの座標データが、1/25秒の周期で記録されている。座標は、ピッチ中央を原点とした空間上の直交座標系で表され、各選手に関しては x 座標、 y 座標が、ボールに関しては、 x 座標、

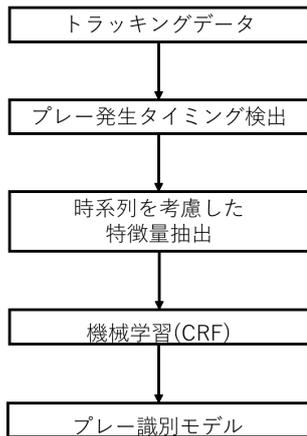


図1 提案手法の概要

y 座標に加えて、地面からの高さを意味する z 座標が記録される。また、選手の座標と紐付けてその選手のチーム、背番号が記録されているが、これらは試合中にスタジアムでオペレーターが手動で記録したものである。本研究では自動化という点に注力しているため、このような手動で記録された情報を用いることはふさわしくない。しかし、選手がどちらのチームであるかといった点については、ユニフォームの色情報を利用することにより比較的容易に自動判別できると考える。そのため、本手法ではトラッキングデータを解析することで得られる各選手、ボールの座標に加えて、各選手がどちらのチームの選手であるかというデータについても利用することとする。

4. 提案手法

4.1 概要

提案手法の概要を図1に示す。

本手法において認識の対象とするプレーはボールタッチプレーである。まず、トラッキングデータよりボールの軌道変化に着目し、各ボールタッチプレーが発生したタイミングを検出する。次に、検出したそれぞれのタイミングごとに、ボールと各選手の位置に関する特徴量を抽出する。そして、抽出した特徴量と正解のラベルを用いて、Conditional Random Field (CRF) を利用して機械学習を行い、プレーの識別モデルを生成する。条件付き確率場、すなわち Conditional Random Field (以下 CRF とする) は Lafferty ら [8] によって提案された、機械学習における学習方法の一種である。CRF は、主に品詞付与 [8] や固有表現抽出 [9] といった系列ラベリング問題に用いられ、高い精度を示している [10]。

本手法において CRF の使用を検討した理由として、プレー認識、すなわちプレーのラベル付けを行うに当たってサッカーで発生するプレーは時系列的に相関性が存在すると考え、CRF ではこのような時系列的な相関性も含めて特徴量として扱うことができると考えたためである。例え

ば「トラップ」というラベルが付与される場合、その1つ前に発生したプレーは「パス」、「スルーパス」、「クロス」といったパス系統のものである確率が大きいと考える。また、「シュート」というラベルが付与される場合、その1つ後に発生するプレーは「ブロック」、「ハンドクリア」といった相手チームが行う守備系統のものであったり、もしくはボールがピッチ外に出たことを表す「ボールアウト」が発生する確率が大きくなると思われる。このため、提案手法では CRF を学習方法として採用し、時系列順に並んだ観測データ系列（各特徴量）に対するラベル系列（プレー種類）について、時系列の前後関係を考慮しながら事後確率が最大となるプレーを推定するアプローチをとった。

本手法では「プレーが開始してからプレーが切れるまでの一連の区間」を一つの時系列とし、この区間内に発生した各ボールタッチプレーを認識対象とする。ここで、プレーの開始とは、キックオフもしくはセットプレー（スローイン、フリーキック、コーナーキック、ゴールキック）が発生することを指し、プレーが切れるとは、ボールがピッチ外に出る、もしくはファールが発生することを指す。一連の区間内で検出された各プレー発生タイミングについて、それぞれのタイミングごとに特徴量を抽出し、これらを時系列順に並べてまとめたものを最終的な特徴量とする。ただし、後の5.1.1節で説明するように、プレーが開始からの数秒間はトラッキングデータに誤差が含まれる可能性が大きいため、この区間については時系列に含めない。さらに、本手法では特徴量として「1つ前のプレー発生時」、「1つ後のプレー発生時」における情報を使用する。そのため、1つ前もしくは1つ後のプレーがない、すなわち時系列内における先頭のプレーと末尾のプレーに関しては本手法では認識することができないため、これらについてはそれぞれ時系列から除外した。

今回はこのようなプレーに関して推定の対象外としたが、ボールのトラッキングデータに誤差が含まれる可能性が大きい区間内で発生したプレーの認識に関しては、選手に関する情報のみで設計する特徴量を用いて、提案手法と並行して別の分類器で推定を行うなどの対策が考えられる。また、時系列の先頭に発生したプレーの認識に関しては、現在と未来の情報のみで構成する特徴量を用いて、トラッキングデータに誤差が含まれる可能性が大きい区間内で発生したプレーと同様、異なる分類器で推定を行うなどの対策が考えられる。一方、時系列の末尾に発生したプレーの認識に関しては、発生後にプレーが切れたことをトラッキングデータやホイッスルの音声情報から検出することで、「次にプレーが切れる」という時系列情報を特徴量に追加することで推定を行うことができないか今後検討していく予定である。

表 1 対象プレーのクラス

番号	クラス名	内容
1	パス	味方選手の足元にボールを出す
2	スルーパス	選手が存在しない前方のスペースにボールを出す
3	クロス	敵陣のサイドからペナルティエリア内へボールを出す
4	シュート	相手ゴール方向を狙ってボールを出す
5	フィード	手に持っているボールをキーパーが前方へ出す
6	クリア	守備側の選手が自陣でボールを大きく前方へ出す
7	トラップ	受け取ったボールを足元に収める
8	ドリブル	ボールを運んで相手選手を交わそうとする
9	キャッチ	キーパーがボールを抱える, または手で掴む
10	タックル	ボール保持選手に対して守備側の選手が接近し奪おうとする
11	ブロック	相手選手が出したボールに体の一部を当てて進路を変える

4.2 対象プレー

今回識別の対象とするプレーのクラスと, 各プレーの内容についてまとめたものを表 1 に示す.

4.3 プレー発生タイミング検出

プレー発生タイミング検出のため, タイムウィンドウ W に対して, ウィンドウの開始時 $t-W$ と終了時 t におけるボール座標をそれぞれ始点, 終点としたベクトル v_b^{t-W} , v_b^t を考える. このとき, 以下の式 (1), (2) のどちらかを満たす場合にプレーであるとして検出する.

$$\frac{v_b^{t-W} \cdot v_b^t}{|v_b^{t-W}| |v_b^t|} \leq \cos \theta_{TH} \quad (1)$$

$$|v_b^{t-W}| - |v_b^t| \geq V_{TH} \quad (2)$$

ここで, θ_{TH} , V_{TH} はそれぞれ角度, 大きさの閾値であり, $\theta_{TH} = 0.6\text{radian}$, $V_{TH} = 0.006\text{m}$ である. これらの閾値は, 本手法において最も F 値が高くなるよう事前実験の結果を踏まえて設定した.

また, プレーでないにも関わらずボールのベクトルが変化するシーンについて, 誤ってプレーとして検出しないよう工夫を行った. 例えば, ゴールキーパーがボールをキャッチした後, 一定時間ボールを持ったまま移動し最終的にフィードを行うというシーンを想定する. このとき検出したいプレー発生タイミングは, キャッチが行われた瞬間とフィードが行われた瞬間のみであるが, ボールを持ったまま移動した区間においてもボールのベクトルが変化するため, プレーでないにも関わらずプレーとして検出されるおそれがある. そのため, ボールと最も近くに存在する選手をウィンドウ内におけるボール保持選手として仮定し, ボール保持選手が同一である区間に発生したボールベクトルの変化についてはプレーとして検出しないようにした.

4.4 プレー識別

4.4.1 Conditional Random Field (CRF)

入力系列 $x = x_1, \dots, x_n$ が与えられた場合の出力であるラベル系列が $y = l_1, \dots, l_n$ となる条件付き確率は, 以下の

表 2 設計した特徴量の詳細

特徴量	対象
時刻 t_i における x 座標, y 座標, z 座標 (絶対値)	ボール
時刻 t_{i-1} における x 座標, y 座標, z 座標 (絶対値)	ボール
時刻 t_{i+1} における x 座標, y 座標, z 座標 (絶対値)	ボール
時刻 $t_i + s$ における x 座標, y 座標, z 座標 (絶対値)	ボール
ゴール方向への接近度	ボール
ベクトルの大きさ (現→次)	ボール
ベクトルの大きさ (現→s 秒後)	ボール
ベクトルの大きさ (前→現)	ボール
ベクトルの大きさ (現→次)	現プレー実行選手
ベクトルの大きさ (現→s 秒後) の大きさ	現プレー実行選手
ベクトルの大きさ (前→現)	現プレー実行選手
ベクトルの大きさ (現→次)	次プレー実行選手
時刻 t_{i+1} における現プレー実行選手, ボール間の距離	現プレー実行選手, ボール
時刻 $t_i + s$ における現プレー実行選手, ボール間の距離	現プレー実行選手, ボール
時刻 t_i におけるチーム A オフサイドラインの位置	チーム A
時刻 t_i におけるチーム B オフサイドラインの位置	チーム B
時刻 t_i におけるチーム A 各選手のベクトルの向き	チーム A 各選手
時刻 t_i におけるチーム B 各選手のベクトルの向き	チーム B 各選手
時刻 t_i におけるボールから 3m 以内の距離に存在する選手数	全選手
時刻 t_i における現プレー実行選手, 最も距離に近い相手選手間の距離	現プレー実行選手, 相手選手

ように与えられる.

$$P(y|x) = \frac{1}{Z_x} \exp\left(\sum_{i=1}^n \sum_k \lambda_k f_k(l_{i-1}, l_i, x)\right) \quad (3)$$

ここで, Z_x は全系列を考慮した場合に確率の和が 1 となるようにするための正規化項であり, 次の式で表される.

$$Z_x = \sum_{\hat{y} \in Y(x)} \exp\left(\sum_{i=1}^n \sum_k \lambda_k f_k(\hat{l}_{i-1}, \hat{l}_i, x)\right) \quad (4)$$

$f_k(l_{i-1}, l_i, x)$ は任意の素性関数であり, i 番目, $i-1$ 番目の出力ラベルと入力系列 x に依存する. ここで素性関数とは, 連続するラベル l_{i-1} , l_i および観測された素性 x が特定の 3 つの組である場合に 1, そうでない場合に 0 を返す関数である. λ_k は素性関数の重みを設定するパラメータであり, 学習データにより値が定められる. $Y(x)$ は入力系列 x に対する出力ラベル系列の集合を指す. 入力系列 x に対して最適な出力である \hat{y} は,

$$\hat{y} = \operatorname{argmax}_{y \in Y(x)} P(y|x) \quad (5)$$

となる. この最適化は, Viterbi アルゴリズムを用いることで効率的に探索を行うことができる [10][11]. 本研究では, CRF の実装に Python 言語のライブラリである PyStruct を用いた [12].

4.4.2 特徴量抽出

前節で述べた手法において検出された各プレー発生タイミング t_i において, トラッキングデータの選手, ボールの座標を元に特徴量を抽出する. 今回設計した特徴量について, 概要および対象とする物体を表 2 で示す.

表 2 で用いた記号, 用語について以下で説明する. t_i に対して, その 1 つ前のプレーが発生した時刻を t_{i-1} , 1 つ次のプレーが発生した時刻を t_{i+1} とする. さらに, 時刻 t_i の s 秒後, s 秒前の時刻をそれぞれ $t_i + s$, $t_i - s$ とする.

なお、今回は $s = 1$ とした。「現プレー実行選手」については、検出したプレー発生タイミングにおいて全選手中ボールと最も距離が近い選手がプレーを行ったと仮定し、この選手のことを指す。同様に、「次プレー実行選手」については、現発生タイミングの1つ後にプレーが検出されたタイミングにおけるボールと最も距離が近い選手を指し、すなわち次に発生したプレーを行った選手のことである。「ゴール方向への接近度」については、現発生タイミングと1秒後それぞれのボールの座標を通る直線を引き、その直線がボールと近い側のゴールラインと交わる点の y 座標絶対値を特徴量として用いた。これにより、ボールの移動方向がゴールに対してどれほど向いているかを表す。また、「ベクトルの大きさ ($a \rightarrow b$)」とは、対象の a 時点における座標を始点、 b 時点における座標を終点とするベクトル \vec{ab} で表現し、このベクトルの大きさを意味する。オフサイドラインの位置とは、各チームの選手11人中、後方（自陣ゴール側）から2番目に位置する選手の x 座標を指す。

表2で示した特徴量を各プレー発生タイミングごとに抽出し、特徴ベクトルを生成する。このとき、特徴ベクトルの各成分はそれぞれスケールが異なり等価に扱うことができないため、各成分の平均が0、分散が1となるよう標準化を行った。全特徴量数を N 、現在時刻を t とし、 n 番目の成分である特徴量を $f_n(t)$ とすると、 N 次元のベクトル $X(t) = [f_1(t), f_2(t), \dots, f_N(t)]$ を $Z(t) = (X - M)/S$ に従い標準化し、特徴ベクトル $Z(t)$ を得る。ここで、 M は各成分の平均、 S は各成分の標準偏差を表す。

提案手法では、検出したタイミングにおける選手、ボールの位置だけでなく、1つ前のプレー発生時、1つ後のプレー発生時、1秒後といった、過去、未来における位置情報についても特徴量として用いた。理由として、サッカーにおいては時系列前後のボール、選手の位置状況によって発生しやすいプレーが異なると考えたためである。例えば、キックを行う種類のプレーに関しては発生タイミングより後のボールの位置情報に特徴が大きく表れ、一方でボールを止める種類のプレーに関しては発生タイミングより前のボールの位置情報に特徴が大きく表れると考えられる。

5. 性能評価

5.1 評価環境

前述の TRACAB と呼ばれるシステムを用いて計測されるトラッキングデータについて、ガンバ大阪の2016年シーズンにおけるリーグ戦において実際に計測されたものを評価用に用いた。今回の評価実験では、ホーム戦とアウェイ戦を共に含む全21試合分のトラッキングデータを使用した。これらのデータには人手で記録されたプレーのラベルが付与されており、これを正解データとして評価実験に用いた。

表3 検出の対象外とする期間

ボールがピッチ外に出てからプレーが再開されるまでの間
ファールが発生してからFKが行われるまでの間
ゴールが発生してからキックオフが行われるまでの間
キックオフ発生後8秒間
スローイン、GK、CK発生後8秒間

5.1.1 プレー発生タイミング検出

提案するプレー発生タイミング自動検出手法について、正解率を評価するために実験を行った。5.1節で述べたプレーデータに含まれる「プレーが発生した瞬間の絶対時間」を正解データとし、推定した発生タイミングと正解の発生タイミングを比較することで、各試合ごとの正解率を評価した。正解の発生タイミングは試合映像を確認しながら人手で記録されたものであり、実際の発生タイミングより僅かにずれた時間が記録されている可能性が存在する。このため、今回はウィンドウ幅を0.2秒とし、推定した発生ウィンドウを基準に前後2ウィンドウ ($0.2 \times 2 = 0.4$ 秒) までのずれを許容するように設定した。また、3.1節で述べたように、トラッキングデータ計測にあたって様々な原因で追跡エラーが発生し、エラー発生後のしばらくの期間はボール、選手の座標に誤差を含む可能性がある。プレー認識の性能評価のため、正解データを参照することで、誤差を含む可能性が大きい期間については検出の対象外とした。加えて、審判のホイッスルが鳴りプレーが止まっている期間についても同様に検出の対象外とした。これらの対象外期間についてまとめたものを表3に示す。今回は正解データを参照して対象の期間を対象から除外したが、位置情報を用いてボールがピッチ外に出たことを検出したり、ホイッスルの音声情報を用いてファールの発生、プレーの再開を検出するなど工夫を行うことで、将来的には自動で該当期間を判別できると考えている。

5.1.2 プレー認識

頑健な学習モデルを構築するために、表2で示した全特徴量で形成された特徴ベクトルのうち、識別に影響のある成分のみを選択する処理を行った。特徴量選択を行うための手法は複数存在するが、今回は計算量の関係上、高速で計算を行うことが出来るランダムフォレストアルゴリズム [13] を利用することで各特徴量の識別に対する重要度を算出し、得られた重要度を参考にして手作業により特徴量選択を行った。

はじめに重要度が大きい順に並び替え、下位30%の特徴量群を選択し、これらの特徴ベクトルの成分から削除した結果、新たな特徴ベクトルを得た。新たに得た特徴ベクトルに対して、CRFで学習を行った結果として得られる各クラスのF値の平均値を基準に、削除した成分のうち重要度が大きいものから順の一つずつ特徴ベクトルに再度加えていき、F値の平均値が極小にしか変化せず、ある一定の値に収束した時点でこの処理を停止した。特徴量選択を行っ

表 4 用いた特徴量の詳細

特徴量	対象
時刻 t_i における x 座標 (絶対値)	ボール
時刻 t_i における y 座標 (絶対値)	ボール
時刻 t_{i+1} における x 座標 (絶対値)	ボール
時刻 t_{i+1} における y 座標 (絶対値)	ボール
時刻 t_{i-1} における x 座標 (絶対値)	ボール
時刻 t_{i-1} における y 座標 (絶対値)	ボール
時刻 $t_i + 1$ における x 座標 (絶対値)	ボール
ボールがどれほどゴール方向に移動しているか	ボール
ベクトルの大きさ (現→次)	ボール
ベクトルの大きさ (現→ s 秒後)	ボール
ベクトルの大きさ (現→次)	現プレー実行選手
ベクトルの大きさ (現→ s 秒後)	次プレー実行選手
時刻 t_{i+1} における現プレー実行選手, ボール間の距離	現プレー実行選手, ボール
時刻 $t_i + s$ における現プレー実行選手, ボール間の距離	現プレー実行選手, ボール

表 5 結果：プレー発生タイミング検出

試合	適合率	再現率	F 値	試合	適合率	再現率	F 値
1	0.857	0.873	0.871	12	0.803	0.822	0.835
2	0.841	0.850	0.864	13	0.839	0.831	0.857
3	0.865	0.895	0.873	14	0.841	0.851	0.867
4	0.795	0.796	0.807	15	0.885	0.897	0.889
5	0.797	0.819	0.819	16	0.857	0.878	0.869
6	0.806	0.875	0.855	17	0.839	0.845	0.856
7	0.829	0.837	0.843	18	0.845	0.868	0.867
8	0.859	0.835	0.851	19	0.831	0.793	0.825
9	0.848	0.851	0.879	20	0.809	0.831	0.837
10	0.860	0.879	0.877	21	0.784	0.819	0.816
11	0.859	0.859	0.859	平均	0.836	0.848	0.853

た結果、本手法では表 4 で示す 14 個の特徴量により特徴ベクトルを作成し、これを評価に用いた。

本評価についても、5.1.1 節で用いたものと同じく、計 21 試合分のトラッキングデータおよび正解データを使用した。交差検証を用いて 7:3 の割合で学習データとテストデータに分割した。このとき、学習データおよびテストデータは、対象とする 21 試合分のデータをランダムに混合したものを使用した。

この際、学習データに含まれるサンプル数の大小に関して、クラスごとに大きく偏りが存在した。クラスごとのサンプル数が不均衡であるまま学習させると、分類器の精度が低下することが知られている [14]。そこで今回施した対策として、最もサンプル数が少ないクラスのサンプル数に合わせて他クラスのサンプル数をアンダーサンプリングし減少させることで、学習データ内における全クラスのサンプル数を同程度に統一する処理を行った。アンダーサンプリングを行った結果、学習データ中の各クラスのサンプル数はそれぞれ 180~190 個の範囲内に統一された。

5.2 評価結果

5.2.1 プレー発生タイミング検出性能

プレー発生タイミング検出手法に関する評価実験の結果について、各試合ごとおよび全体を平均した適合率、再現率、F 値を表 5 に示す。

各試合ごとの結果にばらつきはあるが、全体の平均として適合率:0.836、再現率:0.848 とそれぞれ 0.8 以上を達

成することができ、高精度な検出が行えることがわかった。

各試合ごとに結果がばらついた理由として、試合ごとにトラッキング精度が変化することが考えられる。前述の通りトラッキングデータはカメラ映像を画像処理することで計測されており、スタジアムや天候、両チームのユニフォームの配色などの条件が異なると、トラッキングの精度が影響を受ける。

発生の検出に失敗したプレーとして、ボールの軌道や速度が殆ど変化しなかったプレーが大半を占めた。これは、本手法がプレー発生を検出するにあたってボールの軌道と速度の変化についてのみ着目しているため、閾値以上の大きさでどちらかが変化しないプレーに関して、現状では検出が不可能である。今後、検出の精度を向上させるために、ボールに関する情報を用いるだけでなくボール周辺に存在する選手の移動軌跡や速度の変化を用いることで、今回検出に失敗した類のプレーについても検出できるよう、手法の改善に取り組む必要があると考えられる。

一方で、プレーでないにも関わらずプレーであるとして検出されてしまうものが見受けられた。このようなケースは、一例としてボールが地面でバウンドした瞬間に多く見受けられた。バウンドする直前と直後と比較すると、多くのケースでバウンド直後にボールの移動速度が変化していることがわかった。

また、3.1 節で述べたとおり、本研究で用いるトラッキングデータは誤差を多く含む。今回の評価では、特に追跡エラーが発生しやすいシチュエーションを除外したにも関わらず、誤差が一定以上含まれていた。ゴールキーパーがボールをキャッチしてから放すまでの期間、カメラの視野角から外れるほどボールが高く上がった後の数秒間、複数選手がボールに対して密集した後の数秒間などといったケースで特に追跡エラーが顕著である。これらが起こった際には、実際にはボールが移動しているにも関わらずトラッキングデータ上においては数秒から数十秒間もの期間でボールが一点上で静止したままであったり、実際とは異なる位置情報が計測されていることが多く見受けられた。本手法における正解率をより向上させるためには、このような追跡エラーへの対策を行わなければならない。これについても同様に、ボール周辺に存在する選手の情報を用いることによって改善できないか今後検討していく予定である。

5.2.2 プレー認識性能

提案手法によるプレー認識の混同行列を図 2 に、比較のため正確にプレー発生タイミングが検出できた場合を想定し、プレー認識を行った場合の混同行列を図 3 に示す。

また、各クラスを平均した結果として、提案手法を用いた場合は適合率 0.58、再現率 0.56、F 値 0.56、正確なプレー発生タイミングを用いた場合は適合率 0.66、再現率 0.67、F 値 0.67 という結果が得られ、提案手法を用いた場合は F

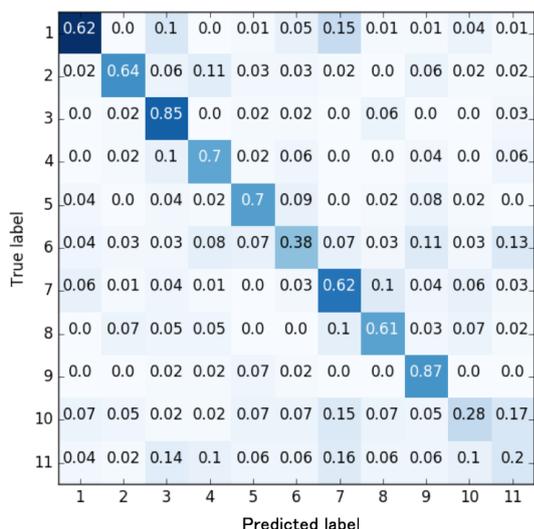


図 2 結果：提案手法で検出したプレータイミングを用いた場合

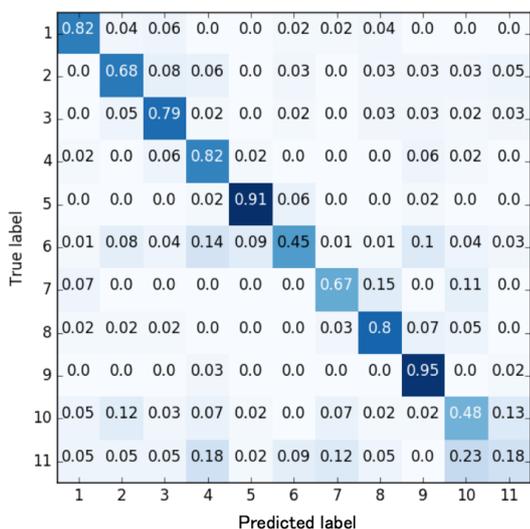


図 3 結果：正確なプレータイミングを用いた場合

値が約 0.1 低下した結果が得られた。このことから、F 値の低下量が少ないため、プレー検出が精度良く行えていることがわかる。

「パス」、「クロス」、「シュート」、「フィード」、「ドリブル」、「キャッチ」についてはおおよそ 0.8 以上の再現率を達成し、そのうち「シュート」を除くプレーに関しては、適合率 0.7 以上を達成したため、これらについては認識率が高い結果となった。一方で、「クリア」、「タックル」、「ブロック」については再現率が 0.5 未満と、あまり認識ができなかった。

「クリア」については、「スルーパス」、「シュート」、「フィード」といった、発生後にボールの位置が大きく移動する系統のプレーとの誤認識が顕著であった。考えられる原因として、「クリア」というプレーの定義が曖昧であるためであると考えられる。「クリア」とは基本的に守備側（ボールを保持していない側）のチームが行う、様々な状況で発生するプレーであり、例えば

- 相手が出したボールを、敵陣方向へ大きく移動させる
- 自陣タッチライン付近にあるボールを意図的にピッチ外へ出す
- ゴールキーパーが空中にあるボールをパンチングするなどが例として挙げられる。再現率 0.8 以上を達成したプレーについてはプレーの定義が明確であるため他のプレーと誤認識することが少なかったが、「クリア」はボールが全方位に移動し得ることも含め自陣で行われるという点以外に目立った特徴はなく、本手法で用いた位置に関する特徴量のみでは認識することが難しい。「タックル」、「ブロック」については、他の様々なクラスとの誤認識が目立った。これら二つは守備側のチームの選手が相手選手に対して行うプレーであるが、発生位置やプレー発生前後におけるボールおよび選手の動きに相関性が殆ど無いため、「クリア」と同様の理由で今回用いた位置に関する特徴量のみでは認識することが困難であると言える。プレーが発生した瞬間やその前後について、どちらのチームがボールを保持しているのかといった情報を本手法では考慮していないが、今後このような情報を加味することにより、攻撃側のチームが行ったプレーであるか、もしくは守備側のチームが行ったプレーであるかを判定することで、今回再現率が低い結果となったプレーの認識精度を向上することができると考えられる。

その他で誤認識が目立ったプレーとして、「スルーパス」を「クロス」や「シュート」として誤る割合が大きかった。これらは全てゴールに近い位置で発生しやすく、発生後にボールが相手ゴール方向に向かって移動するという共通点があるため、誤認識が発生したと考えられる。また、「シュート」と「フィード」をお互いに誤る結果も多く見受けられた。「シュート」は特にペナルティエリア内で発生することが多く、一方で「フィード」はキーパーが自陣ペナルティエリア内で行うプレーである。そのためプレー発生位置に関する特徴が類似していることによりこのような誤認識が発生したと考えられる。加えて、「トラップ」を「ドリブル」として誤認識するケースが目立った。これについては、今回正解として用いたプレーのラベルの付与方法に原因があると考えられる。本来「トラップ」とは受け取ったボールを足元に止めるプレーのことを指すが、正解データのうち「トラップ」のラベルがついたプレーについて映像を見て検証すると、ボールを止めた後にその選手がボールを長距離に渡って持ち上がった様なプレーに対しても「トラップ」というラベルが付与されていることが判明した。すなわち、「トラップ」という正解ラベルと「ドリブル」という正解ラベルについて、映像で確認しても判別することが難しいといったプレーが多々存在したため、今回の誤認識についてもその範疇に収まると考えている。

6. まとめ

本稿では、サッカーの試合で計測されたトラッキングデータを用いて、プレーの発生を検出し、時系列を考慮した上でプレーの種類を自動認識する手法を検討した。

評価実験では「パス、スルーパス、クロス、シュート、フィード、クリア、トラップ、ドリブル、キャッチ、タックル、ブロック」のといった全 11 種類のボールタッチプレーについて、提案したプレー発生タイミング検出手法を用いて、適合率 83%、再現率 85% でプレーが発生したタイミングを自動検出できることを示した。一方で、提案したプレー認識手法を用いて、全体の結果を平均したところ適合率 66%、再現率 67% となり今後に課題が残る結果となったが、特に「パス」、「クロス」、「キャッチ」など一部のプレーの認識に関しては適合率 70% 以上、再現率 80% 以上と高い認識精度が達成できることを示した。

今後は、今回の評価実験において誤認識が多く見られた種類のプレーについて、特徴量の設計を見直すことで認識精度の向上に取り組む。また、トラッキングデータ内に含まれる誤差への対策を考え、例えばボールの追跡に誤りがある場合であっても選手の位置関係等を用いることで、プレー発生タイミング検出の精度向上にも挑戦する。さらに、将来的にはプレーの自動認識を行うだけでなく、認識結果を用いることにより戦術解析を支援したり、現状では手作業で記録されているデータを自動で算出することが可能になるシステムを提案し、サッカーチームの強化に貢献したいと考えている。

謝辞

本研究は、平成 27 年度～平成 29 年度スポーツ庁受託事業「スポーツ研究イノベーション拠点形成プロジェクト (SRIP)」における成果である。

本研究で使用したトラッキングデータ、正解ラベルとして用いたプレーデータおよび試合映像を提供して頂いたデータスタジアム株式会社に感謝の意を表する。

参考文献

- [1] Chen, S. and Feng, Z.: Play Type Recognition in Real-World Football Video, Applications of Computer Vision (WACV), 2014 IEEE Winter Conference, pp.652-659 (2014).
- [2] Lazarescu, M. and Venkatesh, S.: Using camera motion to identify types of American football plays, Multimedia and Expo, 2003. ICME '03. Proc. 2003 International Conference, Vol.2, pp.181-184 (2003).
- [3] Wei, X., Sha, L., Lucey, P., et al.: Predicting Ball Ownership in Basketball from a Monocular View Using Only Player Trajectories, Computer Vision Workshop (ICCVW), 2015 IEEE International Conference, pp.780-787 (2015).
- [4] Kaneki, Y., Misumi, Y. and Miyamoto, M.: Analysis

- of Japanese Football Games by the Tracking Data and Sport Live Event Annotations, Advances in Human Factors in Sports and Outdoor Recreation, pp.39-48 (2016)
- [5] Horton, M., Gudmundsson, J., Chawla, S., et al.: Automated Classification of Passing in Football, Pacific-Asia Conference on Knowledge Discovery and Data Mining, PAKDD 2015: Advances in Knowledge Discovery and Data Mining, pp.319-330 (2015).
- [6] ChyronHego: TRACAB Optical Tracking, available from (<http://chyronhego.com/sports-data/tracab>) (accessed 2017-05-07).
- [7] 加藤 健太: サッカーにおけるデータ分析とチーム強化, 電子情報通信学会 通信ソサイエティマガジン, Vol.10, pp.29-34 (2016).
- [8] Lafferty, J., McCallum, A. and Pereira, F.C.N: Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data, ICML '01 Proceedings of the Eighteenth International Conference on Machine Learning, pp.282-289 (2001).
- [9] McCallum, A., Li, W.: Early results for named entity recognition with conditional random fields, feature induction and web-enhanced lexicons, CONLL '03 Proceedings of the seventh conference on Natural language learning, pp.188-191 (2003).
- [10] 工藤 拓, 山本 薫, 松本 裕治: Conditional Random Fields を用いた日本語形態素解析, 情報処理学会研究報告第 NL161 巻, pp.89-96 (2004).
- [11] 薬師 貴之, 太田 学, 高須 淳宏: CRF を用いた学術論文 OCR テキストからの自動書誌要素抽出, 情報処理学会論文誌データベース, Vol.2, No.2, pp.126-136 (2009),
- [12] PyStruct - Structured Learning in Python - pystruct 0.2.4 documentation, available from (<https://pystruct.github.io/>) (accessed 2017-05-10).
- [13] Chen, Y., Lin, C.: Combining SVMs with Various Feature Selection Strategies, Feature Extraction, vol.207, pp.315-324 (2006)
- [14] He, H., Garcia, E.A.: Learning from Imbalanced Data, IEEE Transactions on Knowledge and Data Engineering, pp.1263-1284 (2009).