

原著論文

実試合データに基づくサッカーエージェントのパスレシーバー選択モデルの構築†

糸田 孝太 *1・渡邊 紀文 *2・武藤 佳恭 *1

近年のエージェント開発では、決められた状況だけに最適化された制御則だけにとどまず、機械学習などの統計や確率的学習手法を取り入れ、不確実な状況に対しても適応能力を持つような動作生成や行動選択のシステムが多く提案されている。本研究では、サッカーにおける集団的戦術行動であるパス行動に着目し、個人の意思決定から集団の行動がどのように最適化されるのかを探る。具体的には、まず人間がどのように予測や決定を行っているのかを、実際の試合のトラッキングデータ及び動画データを分析することで定量化し、その分析を元にパラメータをロジスティック回帰により最適化することでパス行動モデルを構築した。結果として、周辺選手の相対位置に対して主体となる選手の視線方向に重み付けを行うことで、高精度でレシーバーの予測が可能となった。

キーワード：行動モデリング、サッカーパス行動、意思決定、ロジスティック回帰

1. はじめに

本研究では、サッカーにおける目標志向型の集団行動である「パス行動」に着目したモデル構築を行う。パス行動はボールを中心として味方プレイヤー、敵プレイヤーというそれぞれ異なる意図を持つエージェントが同時に行動をする動的で複雑な行動であり、各プレイヤーは周囲の行動を予測した意思決定が必要となる。そこで、人間のサッカーチームの動画像及びトラッキングデータを用いてパス行動の詳細な分析を行い、パスという動作のための意思決定が行われる状況を一般化した個体レベルでのモデルを構築する。さらにモデルをもとにしてロジスティック回帰を用いることで得られたパラメータを学習し、その入力とパラメータの考察をする。また、本論文の最後にロボカップのようなエージェントシミュレーションにおける、本モデルの利用についても検討する。

2. 先行研究

サッカーにとどまらずスポーツにおける選手の行動解析は、主に重回帰分析やエントロピーなどを用いた統計的な手法による集団レベルでの研究が多く行われ

ている。その目的は、スポーツ科学において生徒を指導する際に参考となる指標を分析によって得ようとするもの[1, 2]や、試合データにおける集団行動の可視化を行うもの[3]である。しかしこれらの研究は集団レベルでの指標を得ることにとどまり、集団行動の要因として個体レベルでのパラメータを考慮していない。一方、確率的な手法を用いて行動をモデリングをする研究では、ベイジアンネットワークを利用して、動画像から自動的に幼児の行動のラベリングを行った研究[4]がある。さらに、ロボットに行動モデルとして隠れマルコフモデルを利用し、別のロボットの行動を元にした行動認識と理解、行動の再生を可能とする研究[5]がある。そして、エージェントベースで人間の意思決定をモデル化し、行動の予測から他者の意図推定までを扱った研究[6]がある。これらの研究では、一対一の関係を対象としたマイクロレベルでの意思決定のみを扱っている。一方、本研究は個人の意思決定から、マクロなレベルでの集団行動の創発を理解することを目的とする。

3. 実サッカーデータに基づくパス行動の分析

本章ではパス行動に見られるような選手間の意図の共有、予測などを人間が実際にどのように行っているのかを明らかにするために、人間によるサッカーの試合データを対象とした分析を行う。

† Real-Soccer-Based Pass Receiver Choice Model for Soccer Agents

Kota ITODA, Norifumi WATANABE and Yoshiyasu TAKEFUJI

*1 慶應義塾大学環境情報学部

Faculty of Environment and Information Studies, Keio University

*2 東京工科大学コンピュータサイエンス学部

School of Computer Science, Tokyo University of Technology

3.1 分析対象

分析対象は、データスタジアム株式会社[7]提供の日本プロサッカーリーグであるJリーグの一試合分の動画データ及びトラッキングデータを利用した。動画データはテレビ放送されたものであり、30fpsで記録されている。トラッキングデータはサッカースタジアムに配置された複数台のカメラを利用して25fpsで計測されたフィールド上の全選手及びボール、審判の座標データである。

3.2 分析手法

3.2.1 パス行動シーンの切り出し

本研究では、動画をもとにしたパス行動の切り出しをフレーム単位で行った。分析においてはまず、相手チームのボールを確保し、自チームの多くの選手がシュートを打つまでの行動をとるといった、「集団行動の目的が明らかであるゴールに絡むような攻撃的なパスの展開」であること、次に各フレームにおける選手同士のアイコンタクト及びハンドシグナルが行われている「選手の視線や他選手とのコンタクトから意図の共有、意思決定を行っていると思われる」シーンに着目した。選手の意思決定の判断基準としては、「アイコンタクト」、「ハンドシグナル」の他に「方向転換」、「急激な速度変化」、「注視」に着目した。今回実際に分析に用いたシーンから、方向転換は約120°から160°の角度変化とし、速度変化においては一フレーム

での加速度が平均で約20.08~26.77km/s²とし、注視は視線が約20フレーム間一定方向へ向けられた状態とした。

次に、独自に開発したトラッキングデータの可視化ツールを用いて、動画データでは現れていない選手全体の行動を把握した。図1にシーンの切り出しで利用したツールの概観を示す。

このツールは、グラフを表示することを目的とした「メインウィンドウ部」とデータの作成と図の編集を目的とした「編集ウィンドウ部」に分かれている。メインウィンドウ部では各フレームにおける全選手及びボール、審判のXY平面における位置を、サッカーフィールドを俯瞰した形で表示する(図1-A)。また、コントロールパネル(図1-B)を使うことで、スライダーや数値入力によるフレームの指定や、再生ボタンによる時系列の自動的な表示、選手番号の表示非表示の切り替え、表示間隔の変更が可能となっている。編集ウィンドウ部は、Edit ボタン(図1-C)を押すことで表示される。編集ウィンドウでは、グラフで表示されるタイトルやラベルなどの加工(図1-D)やデータの保存、またグラフ上の二点を指定することでそれを始線とする極座標系を決定し、全選手分の角度データを確認することができる(図1-E)。

このツールを用いることにより、動画に写っている局所的な選手の情報だけでは捉えることのできない選手の行動のタイミングを把握することが可能となる。

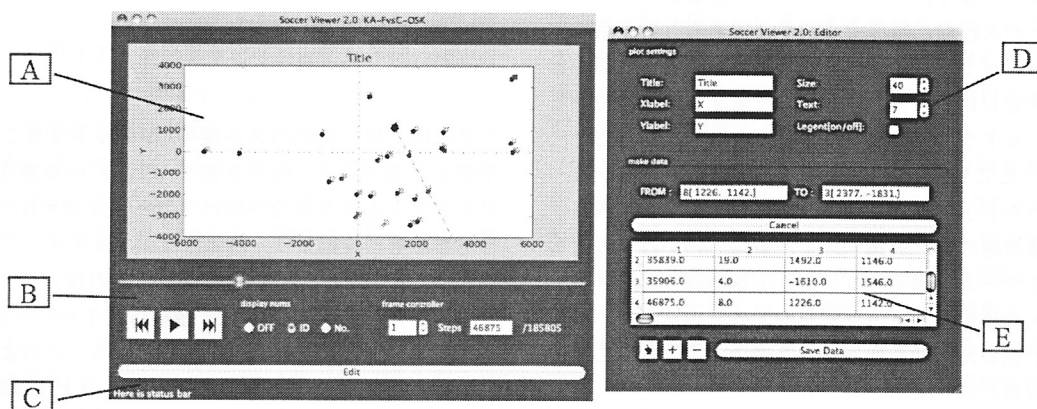


図1 トラッキングデータ可視化ツールの概観 (左:メインウィンドウ, 右:編集ウィンドウ)

- A: プロットウィンドウ, 選手とボール, 審判の座標データ (図の斜め破線は視線を表す)
- B: コントロールパネル, (表示フレーム指定用スライダー, 再生ボタン, ステップの切り替えボタン等)
- C: 図の加工パネル (タイトル, 軸のラベル, マーカーサイズ, テキストサイズ, 凡例)
- D: 図の加工パネル (タイトル, 軸のラベル, マーカーサイズ, テキストサイズ, 凡例)
- E: データ生成パネル (選手の視線を始線とした極座標から他選手全員の角度等の情報を格納するテーブル)

表1 パス行動分析の一例

各行はシーン番号, 着目しているチーム名, フレーム数, 動画における時間, 選手, そのフレームでの行動に対応

Scene	Team	Frame	Time	Player	Action
1	Home	8214	0:04:34:04	C(右側 2 列目下部)	パスを待ち手で合図
1	Home	8214	0:04:34:04	B(右側 3 列目下部)	周囲を見て C を確認
1	Home	8221	0:04:34:27	A(右側 5 列目下部)	敵選手のパスミスを受け取り B へパス
1	Home	8224	0:04:34:37	敵 1(右側 4 列目下部)	A のパスを見て攻撃から守備 に写り方向転換
1	Home	8228	0:04:34:50	C(右側 2 列目下部)	B からのパスを予測しフリー スペースへ移動
1	Home	8247	0:04:35:14	B(右側 3 列目下部)	すぐさま右サイドの C へ間髪 をおかずにパス

また, フレームごとの各選手の座標と行動の確認を動画と照らし合わせながら行うことが可能であり, 選手の座標及びグラフの特定を座標を指定することで選手がフィールド上で向いている方向を取得した。

3.2.2 パスシーンにおける選手の行動の抽出

パスにおける各選手の行動を次のような基準をもとにして抽出した。まず, 試合映像からゴールに関する攻撃的なパスの展開を探し, ボールを保持してからシュートをするまでの一連の流れを一つのパスシーンとする。そして, ボールホルダーと連動して動作するなど, パス行動に関係する選手と考えられる選手をアルファベット(A, B...), また敵選手を敵1, 敵2...と順に決定し(表1), 選手の位置はカメラに写っているフィールドラインの大まかな位置をもとに記録した。なお, ここでのフィールドラインとは, サッカーフィールド上でゴール方向に対して垂直方向に入る, 縞模様の線のことを指す。また敵については, 着目しているチームの選手のコンタクトを確認してパスコースに入り込むことや, マークをするといった, パス行動を予測した行動を取っている選手のみに限定して分析の対象に含めた。

分析の例を表1と図2に示す。ここで着目しているシーンは, 相手チーム(ここではアウェーチーム)の攻撃シーンにおけるパスのミスから, 着目するチーム(ここではホームチーム)が守備から攻撃に転じてシュートを打つまでを一連の流れとしたもので, 表1はその抽出結果の一部となっている。また, 表1にある内容が実際の試合でどのように起こっているのかを, 概念図として図2に示した。

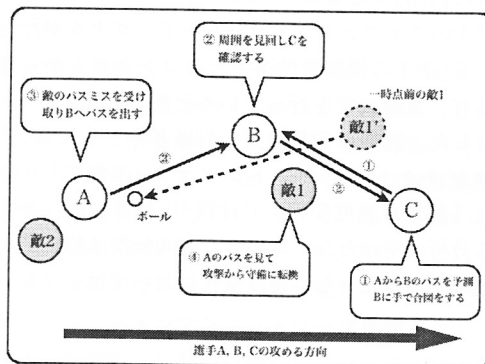


図2 パス行動の分析対象シーン例

この例では, 敵のパスを選手Aがカットすることを予測した選手Cが, 自分と選手Aの間にいる選手Bにコンタクトを送り自分へのパスコースを選手Bに意識させることから始まる。次にほぼ同じタイミングで選手Bが選手Cによる合図を確認し, その後選手Aが実際に選手Bへのパスを行い, 最後に選手Bが選手Cへパスを実行するまでの記述となっている。このようにフレーム単位で分析することで, 表1のような約1秒間における, 各瞬間の選手の行動と予測を把握することが可能となる。

3.3 分析結果

今回はJリーグ1試合分の試合前半から, 3.2節で述べた分析手法を用いて5シーン分のパス行動の分析を行った。今回分析に用いたチームの特徴としては, ホームチームはペナルティエリアに味方選手が集まり




図3 ボールホルダーを基準とした全選手の極座標分布
 左. 敵が周囲に集まっている状況でボールを一番近い味方に出すパターン
 中央. 敵が周囲に集まっている状況でボールを出すパターン
 右. 敵と味方が混在している状況でボールを出すパターン
 (白丸が味方選手, 黒丸がボールホルダーとそのレシーバー, 0°はボールホルダーの始線方向, 距離は最大値が1となるように正規化している)

やすく、ゴール前でのパス回しから得点につなげる事が多く、アウェーチームは中盤の選手が主にパスを回して得点につなげていくという特徴を持っている。また、両チームとも攻撃的なチームである。

分析の結果、分析に用いた5シーンにおけるパスに関して次の二点が重要であることが分かった。まずパス行動に関係する選手は、ボールホルダー、ボールを持っていない選手によらずその視線に基づき自分から次にボールをつなぐ味方選手を決定すること。次に実際にパスをする対象は必ずしも一番距離が近い味方の選手ではなく、21場面中6場面で敵や味方の分布によって自分から遠い位置にいる選手になることが確認された。そこでさらに分析を進めるため、各フレームにおけるボールホルダーの視線を基準とした極座標系に選手の配置をグラフ化した。図3に分析結果の一例を示す。

その結果、パス行動を主に次の二つのタイプに分けられることが確認された。第一に「敵が周囲に集まっている状況で、ボールを出すパターン」(図3左・中央)、第二に「敵や味方が混ざり合って集まっている状況でボールを出すパターン」(図3右)である。第一のタイプでは、一番近い味方選手をレシーバーとするものと(図3左)、危機的状況を脱して展開を大きく変えるために離れた味方をレシーバーとするもの(図3中央)に分けることができる。第二のタイプでは、敵と味方が混在するためにボールホルダーの味方で、かつ周囲に敵がいない選手を選択している(図3右)。

3.4 分析の考察

ボールホルダーが敵の分布に基づきレシーバーを選択することは、攻めると同時に敵にボールを奪われないことを目的とするサッカーにおいて当然の結果だと考えられる。なお分析の結果得られたパターンについては、4章で述べるモデルのパラメータを用いることで定量的な評価と考察を行う。また、選手の視線は、周囲の確認から選手同士の意図共有及び推定に至るまでの基本的な指針になると考えられる。そこでボールホルダーの視線方向を考慮することでパスに関係する選手を推定できると考え、視線に重みを付けた分布からパス行動に関係する人数を評価した。

選手の視線に対して等方位十二段階に角度を分割し、前方から左右対称に{0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0}の順に距離に対する角度の重み付けをし、重み付きの距離を用いた選手の分布をグラフ化した(図4)。結果、分析中のすべてパス行動において視線重みフィルタを用いることで、ボールホルダーを中心とした分布の中で実際のレシーバーが味方選手三人以内に収まることが確認された。

パス行動で考慮すべき人数を三人に絞り込むことは、実際のサッカーにおいても妥当性があると考えられる。ボールホルダーがパスの対象として同時に四人以上の多数を考えることは、敵がある程度強い場合はほぼ不可能である。また逆に、対象を二人に絞り込んでどちらかを選択することは、パスコースが敵選手一人にでも塞がれた場合選択肢が一つにしぼられてしま




図4 角度重みによって選出された敵味方三人の分布の例

左. 敵が周囲に集まっている状況でボールを一番近い味方に出すパターン
 中央. 敵が周囲に集まっている状況でボールを出すパターン
 右. 敵と味方が混在している状況でボールを出すパターン
 (白丸が味方選手, 黒丸がボールホルダーとそのレシーパー, 0°はボールホルダーの始線方向, 距離は最大値が1となるように正規化している)

い, 高いリスクを伴う. また, ボールホルダーを中心とした周囲の少数の選手との連携が, 試合を優位に進める上で重要とする研究もある[8]. それゆえ, 三人を対象とすることは最も適当であると考えられる. さらに敵選手についても, 一度の判断で考慮できる人数はそれほど多くないと考えられるため, 味方選手同様三人程度ではないかと予想できる. したがって図4の分析結果から, 各選手はパス行動時の意思決定において, その視線に基づく敵と味方各三人の分布から次にボールをつなげる対象を決定すると考え, パス行動のモデルを構築する.

4. パス行動モデルの構築

3章で述べた実サッカーデータに基づいた分析結果をもとに, パス行動のモデル化を試みる.

4.1 モデルの概要

パス行動のモデル化において, 確率的識別モデルであるロジスティック回帰を用いる. ロジスティック回帰は出力を確率値とする識別器で, SVM(サポートベクターマシン)のような決定論的なモデルとは異なり, 出力に対する不確実さを定量的に評価することが可能である. また, 誤差関数が凸型になるため, 学習における局所最適解が大域的最適解と一致し, ニューラルネットワークのように局所解に落ち込む心配がない. さらにパラメータが入力次元に縛られる為, ブラックボックス化せず明示的にパラメータの考察をす

ることが可能となる. 以上の理由から本研究ではロジスティック回帰を用いた.

4.2 入力データとパラメータの学習

4.2.1 サンプルデータ

モデルを作るにあたり, 分析に利用した一試合を含む三試合分のトラッキングデータから100場面のパスをサンプルデータとして抽出した. なおサンプルデータとしたシーンは, 分析の際に着目した「攻撃的な展開」を対象とし, 味方への直接的なパスに限定した.

4.2.2 視線重みフィルタ

3章における分析結果から, パス行動を決定する選手の視線により, パスを受ける味方選手を予測することができると考えられる. そこで今回はモデルの作成にあたり, 図5の視線重みフィルタを用いた.




図5 視線重みフィルタ

図5の矢印は意思決定をする選手の視線方向を表す。このフィルタでは選手の視界120°を重み付けの対象とし、24°ずつ五つに等分割して視線方向から順に{0.3, 0.6, 0.8} (左右対称)とする。これらは敵味方全選手の距離に対する角度の重みとして掛け合わされ、意思決定を行う主体の視線方向にいる選手ほど実際より「近い」と見なされる。

また、このフィルタを用いることでパス行動において考慮すべき味方と敵選手を、各フレームにおける視線重み付き距離の小さい選手上位三人として決定した。なお、自分が攻める方向のゴールも、ボールを出す対象に含まれると考え、考慮される味方選手の一人とした。

4.2.3 モデルの適応

パスにおけるボールホルダーの意思決定は、4.2.2項で述べたフィルタを用いて味方と敵選手三人を選び、その味方三人の内での選手を選択するかという識別問題に帰着する。

そこで本研究では、ロジスティック回帰モデルを利用し式(1)、出力分布にベルヌーイ分布を仮定することで学習を交差エントロピー誤差関数の最小化とし式(2)、確率的勾配降下法を用いてパラメータの学習を行った式(3)。また、識別方法の違いにより大きく分けて次の二通りのモデルを作成した。第一のモデルは、敵味方選手六人をひとまとめとして扱い、その味方三人の中から対象となる選手一人を選ぶ多クラス分類器。第二のモデルは、味方三人それぞれに対して視線方向の軸を考え、その軸に対する残り五人の選手の分布から識別を行う二クラス分類器である。多クラス分類器は選手の位置関係を全体のパターンとして学習するが、二クラス分類器の場合は主体と対象となる選手の一対一に対する周囲の選手のパターンとして学習する為、前者よりも汎化能力が高い事を期待して設計を行った。

$$y = \sigma(\mathbf{w}^T \mathbf{x}') \quad (1)$$

$$E_n(\mathbf{w}) = -\{t_n \ln y_n + (1 - t_n) \ln(1 - y_n)\} \quad (2)$$

$$\mathbf{w}_{new} = \mathbf{w}_{old} - \eta \nabla E_n(\mathbf{w}) \quad (3)$$

式(1)における \mathbf{x}' はフィルタ後の入力変数を用いており、多クラス分類では六選手分の距離と角度の十二次元、二クラス分類では五選手分の距離と角度の十次元ベクトルである。 \mathbf{w} はモデルにおけるパラメータである。また $\sigma(\cdot)$ は多クラス分類ではソフトマックス関数、二クラス分類ではシグモイド関数をそれぞれ用いた。式(2)における t は教師データであり正しいク

ラスには1、それ以外のクラスには0として符号化される。多クラス分類の場合は式(2)が多クラス交差エントロピー誤差関数となる。式(3)におけるは学習率であり、今回は学習スケジュールとして初期値0.1から訓練を開始し、全訓練データを使って更新を終えるたびに値を0.95倍し、パラメータの変位が0.001より小さくなった時を学習の収束条件とした。なお入力する距離及び角度は、単位をそろえるために全体で平均0、標準偏差1の正規分布に従うよう正規化を施した。また、入力する角度は、4.2.2項で示したフィルタの区分を利用した六段階の離散化と等方位十二分割の離散化を利用する。

4.3 モデルの評価

4.3.3項で述べたそれぞれのモデルを評価するため、LOOCV(Leave-one-out Cross Validation; 一つ抜き交差確認)を用いて正答率を算出する(表2)。LOOCVを用いることで、サンプルデータ全体が一回ずつテストデータとなるように、訓練データとテストデータの分割を繰り返し、各テストデータに対する正答数を平均することで対象とするモデルに対する汎化誤差を正答率として求める。本研究の場合、訓練データとテストデータの分割はパスシーンの99個分と1個分とし、一つのモデルに対して100回分割の繰り返しを行う。

<多クラス分類器>

- モデル1：重み付けなし距離及び六段階離散角度
- モデル2：重み付き距離及び六段階離散角度
- モデル3：重み付き距離及び十二段階離散角度

<二クラス分類器>

- モデル4：重み付けなし距離及び六段階離散角度
- モデル5：重み付き距離及び六段階離散角度
- モデル6：重み付き距離及び十二段階離散角度

結果として、多クラス分類器で入力を重み付けなし

表2 各モデルの LOOCV 正答率

モデル1(多クラス)	95.00%
モデル2(多クラス)	94.00%
モデル3(多クラス)	93.00%
モデル4(二クラス)	65.33%
モデル5(二クラス)	77.67%
モデル6(二クラス)	79.67%

の距離及び視線重みフィルタを適用して六段階に離散化した角度を用いたモデル1がもっとも高い正答率を出し、重み付けなしの距離及び六段階離散角度を用いた二クラス分類器であるモデル4の正答率がもっとも低くなるという両方法で逆の結果となった。

4.4 モデルの考察

4.4.1 学習結果に関する考察

意思決定をする主体の選手を中心とした、六人すべての選手の位置を入力とする多クラス分類の結果が、味方選手それぞれに対する位置を仮定する二クラス分類より優れた結果となった理由は、次のように考えられる。本研究におけるモデル構築は、意思決定の主体の視線重みから考慮する選手を決定し、その三人の中でパスを受けている一人として訓練データを与えた。そのフィルタをかけた時点で、周囲の選手の位置は主体を中心として決まり、二クラス分類器ではその位置を味方それぞれに対して計算しなおしたため、フィルタの効果が失われたと考えられる。

また、分類器の中でも距離に対する重みの有無で結果が左右されることは、モデルが状況の汎化を行う上で、多クラスの場合にはフィルタをかけた後の全選手の位置をそのまま用いているので、距離が重みによって変化してもモデルの出力はある程度頑健となる。しかし二クラスの場合は、角度情報が距離に対する視線重みとは別に対象となる選手に対して決まる。そのため、重みのない距離を使ったモデル4では、フィルタの段階で決まった主体の周辺分布を無視した形となり、それよりも主体の視線によって決まった重み付き距離及び、十二段階離散角度を使い後方まで角度を分割したモデル6が精度を上げたと考えられる。

4.4.2 パラメータに関する考察

もっとも高い正答率であったモデル1のパラメータについて考察をする。図6はモデル1におけるパラメータ行列のヒント図[9]である。

図における四角形はパラメータの大きさを表している。また、各行は考慮する味方選手三人に上から順に対応している。一列目は学習におけるバイアスとなっ



図6 モデル1のパラメータ行列のヒント図 (白が正值, 黒が負値, 最大値が1となるよう正規化をしている)

ており、二列目から味方選手三人、敵選手三人の順に距離と角度を交互に表す。

この図から、一行目に多くの重みが集中し、中でも特に味方選手の位置に関しての重みが強いことが分かる。また一番近い味方選手の角度と一番近い敵選手の距離に強い負の値が表れ、それ以外の味方選手には中程度の正の値が表れている。このことから、一番近い敵選手が主体にかなり接近し、味方の位置が遠い時に、一番目の味方選手が視線方向に近い位置にいればその選手がパスの対象として選ばれやすいといえる(図7左)。また、3章の分布のタイプとして考察した「周囲に敵が集まっている状態で、ボールを出すパターン」を考えると、このモデルにおいて一番近い敵の距離が小さいという条件付きで、一番近い味方選手にボールを逃がすということが予測される(図7中央)。逆に一番近い敵選手が主体から離れていればそれだけ一番近い味方選手の値は下がり、例えば三番目に近い味方選手が視線方向にいて、その選手が選ばれることが予測される(図7)。また、「敵や味方が混ざり合っている状況でボールを出すパターン」も一番近い敵選手の位置と一番近い味方選手がある程度離れている時に、二番目の味方選手が選択されることが考えられ、分析時に分類した各パターンにおいてもモデルパラメータからボールホルダーが選択するレーシーバーを正しく予測できると考えられる。

さらに、本モデルから得られたパラメータを用いて実際のサッカーにおける集団行動を推察する。例えば、敵陣にパスを用いて攻め込む場合、基本的に敵がボールを奪う為にボールホルダーの周囲に集まることが考えられる。ここで、敵陣に深く切り込む為には、




図7 選手の位置関係による予測の例

左：一番目の味方選手が選ばれる状況
 中央：周囲に敵が集まっている状態でボールを出すパターン
 右：敵や味方が混ざり合っている状況でボールを出すパターン
 (白丸が味方選手, 黒丸がボールホルダーとレーシーバー, 敵が×印でホルダーの視線方向を矢印で表す)

できるだけ敵のゴール方向にいる遠い味方選手にボールを運ぶことが望ましい。先述の「周囲に敵が集まっている状態」における意思決定を想定することで、できるだけ一番近い敵選手を寄せ付けないようにポジショニングをし、遠くの味方選手に対してパスが成功する可能性を上げる事が考えられる。実際の試合においても、縦方向に長いパスが連続して生じる状況では、ボールホルダーに対する一番近い敵選手の位置が要因として大きく働いていると考えられる。

4.4.3 自律行動型エージェントによるパスコースの推定

4.4.1及び4.4.2の考察を踏まえ、ロボカップサッカーシミュレーションのような自律行動型エージェントプログラムへのモデルの応用場面を考える。今回構築したモデルは、ボールホルダーが意思決定をする際に周囲の選手の分布から次のレシーバーを決定するものである。これはボールホルダーだけにとどまらず、ボールを持っていない選手にも適応することができ、その場合は選手が将来ボールホルダーになった場合に想定できるパスコースであると考えられる。そして、このモデルを全選手が持つことで、他の選手の意思決定を予測可能と考えられる。

本研究で取り扱ったロジスティック回帰モデルの確率的識別の側面を重視し、確率値をその対象に対する不確実さの評価とすることで、自分から次の選手、さらに次の選手、と再帰的に確率を計算してより評価の高い経路をパスコースとして決定することが可能とな

る。逆に、守備の面において敵の攻撃の経路をモデルパラメータに基づいて予測し、攻撃に対する防御や敵選手のマークとして活用することも可能と考えられる。

また、識別結果を確率値として出力することで、実際にパスをするタイミングを判断することが可能となる。図8は実際にモデルを構築する際に、学習データとして用いたパスシーンの30フレーム分を時間窓として切り出したものである。時間経過とともに各選手に対する確率値が変化し、図8では25フレームにおいて95%以上の確率値を得た最も近い味方に対して実際にパスが行われている。

5. おわりに

本論文では、サッカーにおけるパス行動の動画データ及びトラッキングデータを用いた分析結果に基づき、ロジスティック回帰モデルを利用することでモデルを作成し、学習パラメータの評価を行った。分析においては、選手の視線方向を基準として敵味方およそ三人を判断要素として用いることが示された。また、モデルの構築においては、分析で得られた視線とパスの対象とすべき選手の仮定から出発し、多クラス分類器を用いることで九割以上の精度で実際のパス行動を予測できた。今後は、シミュレーション環境を用いることで今回得られたモデルの妥当性を評価するとともに、守備的状况におけるパスや、パスの対象とすべき選手が点推定ではない、スペースへのパス、またスルーパスやセンタリングのパス等のモデルの拡張を検討する。

謝辞

本論文において使用したJリーグの映像及びトラッキングデータは、玉川大学脳科学研究所大森隆教授、福岡大学工学部秋山英久氏からご好意により研究にて利用させていただいた。

参考文献

- [1] 大西圭子, 大場渉. 小学校バスケットボール授業におけるゲームパフォーマンスの評価に関する探索的研究. 大阪教育大学紀要第5部門教科教育, Vol.56, No.1, pp.49-61, 2007.
- [2] 横山慶子, 山本裕二. ボールゲームにおけるチーム内連携のダイナミクス-6人制フィールドホッケーによる検証-. *Cognitive Studies*, Vol.18, No.2, pp.284-298, 2011.
- [3] 高橋翔, 今宏史, 長谷山美紀. アクティブネットを用いたサッカー映像におけるパス可能領域の推定(画像認識, コンピュータビジョン). 電子情報通信学会論文誌. D, 情報・システム, Vol.92, No.4, pp.501-510, 2009.

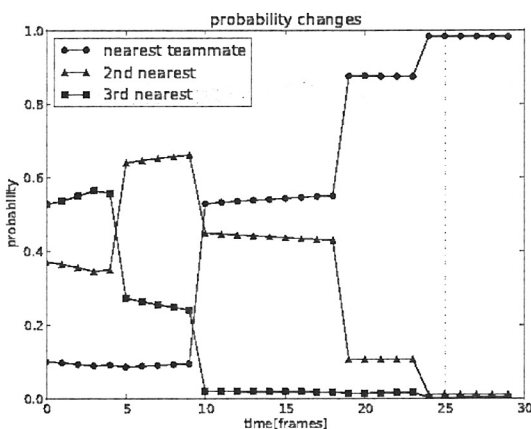



図8 モデル出力確率値の時間的变化
図の黒丸の折れ線が最も近い味方に対する確率の変化、灰色の折れ線が二番目に近い味方、白が三番目に近い味方に対応。25フレーム地点で実際にパスが行われている。

- [4] 河田諭志, 本村陽一, 西田佳史, 石川詔三, 田中和之. 室内における幼児の行動予測のための確率的因果構造モデルの学習と推論. 電子情報通信学会技術研究報告, NC, ニューロコンピューティング, Vol.107, No.542, pp.279-282, 2008.
- [5] 稲邑哲也, 中村仁彦, 戸嶋巖樹, 江崎英明. ミメシス理論に基づく見まね学習とシンボル創発の統合モデル. 日本ロボット学会誌, Vol.22, No.2, pp.256-263, 2004.
- [6] 横山絢美, 大森隆司. 協調課題における意図推定に基づく行動決定過程のモデル的解析 (ヒューマンモデル, 特集人とエージェントのインタラクション論文). 電子情報通信学会論文誌, A, 基礎・境界, Vol.92, No.11, pp.734-742, 2009.
- [7] データスタジアム株式会社, Data Stadium Inc., <http://www.datastadium.co.jp>.
- [8] Yuji Yamamoto and Keiko Yokoyama. Common and unique network dynamics in football games. *PLoS one*, Vol.6, No.12, p. e29638, January 2011.
- [9] G. E. Hinton, J. L. McClelland, and D. E. Rumelhart. Distributed Representations. pdf, 1986. (2013年9月9日 受付)
(2013年11月26日 採録)

[問い合わせ先]

〒252-0882 神奈川県藤沢市遠藤5322
慶應義塾大学 環境情報学部
糸田 孝太
TEL: 090-5542-0417
FAX: 090-5542-0417
E-mail: t10098ki@sfc.keio.ac.jp

著者紹介



いとだ こうた
糸田 孝太 [非会員]

2010年, 慶應義塾大学環境情報学部入学, 現在に至る。ロボカップ3Dシミュレーションを用いた選手の自己位置推定の開発を行う。近年は人間の集団行動における意思決定を, 自律行動型エージェントによるシミュレーションを用いて解明する研究に従事。



わたなべ のりみ
渡邊 紀文 [正会員]

2008年, 慶應義塾大学大学院政策・メディア研究科後期博士課程修了, 博士(政策・メディア)。2008年, 玉川大学脳科学研究所知能ロボット研究センター嘱託研究員, 2012年, 東京工科大学コンピュータサイエンス学部助教, 現在に至る。視覚情報処理に関する神経回路モデルの研究に従事, 近年は, 眼球運動およびモーションキャプチャ計測等を行い, 人間の錯覚を利用した行動誘導について模索している。



たけふじ よしやす
武藤 佳恭 [非会員]

1978年, 慶應義塾大学工学部電気工卒, 1980年同修士課程修了, 1983年同博士課程修了。工学博士。1983-1985年, 南フロリダ大学コンピュータ学科助教, 1985-1988年, 南カロライナ大学コンピュータ工学科助教, 1988-1996年, ケースウェスタンリザーブ大電気工学科准教授, 1992年 tenured 受賞, 1992-1997年, 慶大環境情報学部助教, 1997-現在, 同大教授。研究: ニューラルコンピューティング, セキュリティ, インターネットガジェット。1989年NSF-RIA賞, 1992年IEEE Trans. on NN功労賞, 1980年IPSJ論文, 1993年TEPCO賞, 1993年KAST賞, 1995年高柳賞, 1997年KDD賞, 1999年NTT tele-education courseware賞。2003年US-AFOSR受賞。第一回JICA理事長賞。30冊の本と300編以上の科学論文。

Real-Soccer-Based Pass Receiver Choice Model for Soccer Agents

by

Kota ITODA, Norifumi WATANABE and Yoshiyasu TAKEFUJI**Abstract :**

In recent years, autonomous agents have been developed using statistical and probabilistic machine learnings together with deterministically optimized control. In this paper, a new decision making and motion generation method is proposed for adapting to uncertain environments. In the proposed method, we concentrate on passing in soccer, as a tactical group behavior, and understand how the optimization occurs in a group behavior from individual decision makings. In particular, we have quantified how people pass in plays by analyzing a video and tracking data of real soccer, and have constructed pass models with optimized parameters using logistic regression based on the analysis. As a result, our model predicted the next receiver with a high degree of accuracy by weighting positions of the players around the passer.

Keywords : Behavioral Modeling, Soccer Passing, Decision Making, Logistic Regression

Contact Address : Kota ITODA

Faculty of Environment and Information Studies, Keio University

5322, Endo, Fujisawa-shi, Kanagawa, 252-0882, Japan

TEL : 090-5542-0417

FAX : 090-5542-0417

E-mail : t10098ki@sfc.keio.ac.jp