

博士論文 令和2年度(2020)

人間の協調的集団行動における行動決定過程のモデル構築

慶應義塾大学大学院 政策・メディア研究科

糸田孝太

博士論文要旨 令和2年度(2020年度)

人間の協調的集団行動における 行動決定過程のモデル構築

複数の人間からなる協調的集団行動は、お互いの意図推定に基づく動的で複雑な系を構成する。人間の集団行動として集団球技や日常における協力を考えると、特に意識する事なく参加者はお互いの意図を推定し合う事で円滑な協調を実現している。しかしこのような人間の協調的集団行動を実現する個人の行動決定や意図推定の過程は未だ明らかになっていない。この問題に取り組むためには、実際の人の集団行動を分析するだけに留まらず、人の戦略の仮定をもとにエージェントモデルを構築し、その振る舞いを評価する事で内部過程を検証していく事が重要と考えられる。本研究はそのような複雑な集団行動の中にも一定のパターンや状況があり、それが人の瞬間的な判断を可能にすると仮定し、実際の集団球技及び協調課題を用いる事で、実際の人の行動分析とモデル構築を行うため以下の四つの研究を行った。

第一の研究では、複数の意図を持つ他者が同時に存在し動的に状況が変化する中における行動決定の法則性を探るため、サッカーの実試合データを用いて最も基本であり重要な協調行動であるパスレシーバ選択行動の分析とモデル構築を行った。第二の研究では、さらに個人の行動決定だけでなく集団行動の中でそれぞれの行動がどのように関係し合うのかといった事に着目し、そのような協調のパターンがどのように集団行動の中で現れるのかの分析を行った。この研究ではサッカーとハンドボールの位置トラッキングデータを用いて行動モデルを構築し、さらにそれぞれ異なる集団行動における選手間の行動関係の抽出を行った。第三の研究では、そのような協調パターンがどのように獲得されるのかを明らかにするために、選手の参照行動として視線行動に着目し、仮想環境を用いた行動実験を行った。第四の研究では、動的に共通目標を切り替える過程を協調課題として設定する事で、その時々において目的と注目すべき他者を選択する内部戦略の差異を明らかにするため、被験者行動分析からエージェントモデルの構築とシミュレーションを行った。それにより、協調的集団行動における行動決定において実際に被験者に共有されるような協調のパターンとお互いの意図の誤推定を防ぐような戦略の共有が行われている事を明らかにした。

これらの研究から、今後の展望としてさらなる分析による集団行動の理解に繋がるための行動決定過程のモデルを考える。このような人間の集団における情報処理のモデル化が、将来集団において協調を行うエージェントや社会的ロボットといった情報システムの構築に役立つ事が期待される。

キーワード

1 協調的集団行動 2 行動決定過程 3 意図推定
4 協調パターン 5 エージェントモデル

慶應義塾大学大学院 政策・メディア研究科

糸田 孝太

Abstract of Doctoral Thesis Academic Year 2020

Model Construction of Action Selection Process in Human Cooperative Group Behavior

Cooperative group behavior of multiple persons forms one of the complex dynamic systems based on intention estimations with each other. In a group sports as a typical example or cooperation in our daily lives, the participants perform flexible cooperative behaviors by estimating others' intentions. However, the mechanism of individual action selection and intention estimation processes which enables the cooperative group behaviors has not yet been clarified. To approach these problems, not only analyzing the actual human group behavior, but also agent modeling based on hypotheses based on human strategies and evaluation of the behavior of the model to validate the inner process are important. In this research, we hypothesized the cooperative patterns enable the instantaneous decisions in these complicated group behaviors and conducted four researches of human behavioral analysis and model construction.

In the first research, we have analyzed pass receiver selections as the most important cooperative behavior in soccer and constructed models to clarify the rules of action selection in dynamic situation differences of multiple intentions of participants. In the second research, we have focused on how the behaviors have relationships with each other from individual action selection and analyzed how such cooperative patterns appear in group behavior. In the third research, we have focused on the gaze behavior as the referencing behavior and held behavioral experiments using a virtual environment to clarify how these cooperative patterns are acquired. In the fourth research, we have prepared a cooperative task consisting of the dynamic changes of shared purposes and analyzed the subjects' behavior, agent modeling and simulation to the difference of the inner strategies of deciding the targets and allies in each timing. Through these researches, we have clarified the cooperative patterns and sharing of the strategies to prevent each intention misunderstanding.

In the future research, information processing models for understanding of the group behaviors will be constructed. The research of modeling cognitive process of human group is expected to construct an information system of agents and social robots in cooperative groups.

Key Word

1 Cooperative Group Behavior 2 Action Selection Process 3 Intention Estimation
4 Cooperation Pattern 5 Agent Model

Keio University Graduate School of Media and Governance

Kota Itoda

目次

第1章 序論	1
1.1 研究背景	1
1.2 研究目的及び概要	2
1.3 本論文における用語の定義	4
1.4 本論文の構成	6
第2章 本研究の位置付け	7
2.1 人間・機械の概念, 内部モデル獲得に関する計算論的アプローチ	7
2.1.1 概念, 内部モデルの獲得	7
2.1.2 協調の計算モデル	8
2.2 スポーツにおける数理的アプローチ	9
2.3 多人数インタラクションに関する分析的アプローチ	9
第3章 実試合データを用いたパスレシーバ選択のモデル構築	11
3.1 実試合におけるパス行動の分析	11
3.1.1 分析の目的	11
3.1.2 分析対象	11
3.1.3 分析手法	11
3.1.4 分析結果	13
3.1.5 分析の考察	15
3.2 パス行動モデルの構築	16
3.2.1 モデル構築の目的	16
3.2.2 モデルの概要	17
3.2.3 入力データとパラメータの学習	17
3.2.4 モデルの評価	18
3.3 シミュレーションによるモデルの評価	21
3.3.1 シミュレーションの目的	21
3.3.2 シミュレーション	21
3.3.3 シミュレーションの結果	22
3.3.4 シミュレーションの考察	22
3.4 今後の課題	23
3.5 結論	24

第 4 章	選手行動間の予測に基づく因果性分析	25
4.1	選手行動間の関係の分析の目的及び概要	25
4.2	分析対象	26
4.3	分析手法	26
4.3.1	選手の移動行動モデル	28
4.3.2	予測に基づく因果性分析	28
4.4	ハンドボールにおける集団行動の因果性分析	29
4.4.1	選手行動の行動モデルによる分節化	29
4.4.2	各集団行動における行動間の因果性の分析	31
4.4.3	考察	31
4.5	サッカーにおける集団行動の因果性分析	33
4.5.1	選手行動の行動モデルによる分節化	34
4.5.2	各集団行動における行動間の因果性の分析	35
4.5.3	考察	35
4.6	まとめ	36
第 5 章	仮想環境を用いた視線行動に関する協調パターン獲得実験	38
5.1	視線行動分析の目的及び概要	38
5.2	視線データ獲得用ツールの作成	38
5.3	HMD と仮想環境を用いた実験環境	40
5.4	視線行動に関する概念獲得実験	43
5.4.1	実験に用いる場面	43
5.4.2	実験手順	44
5.5	事前・事後フェーズにおける視線時系列変化	44
5.5.1	全体と攻撃の各段階における分散の変化	44
5.5.2	ボールを受ける直前の変化	46
5.5.3	実際に注視していた選手の分析	47
5.6	考察	48
5.7	まとめ	49
第 6 章	協調課題パターンタスクを用いた協調行動の分析とモデル構築	50
6.1	研究背景	50
6.2	パターンタスク	51
6.3	人被験者による行動実験	52
6.3.1	実験結果	52
6.3.2	考察	54
6.4	エージェントシミュレーション	55
6.4.1	エージェントモデル	55
6.4.2	実験結果	56
6.4.3	考察	58
6.5	まとめ	59

第7章	まとめと将来の課題	62
7.1	実試合データを用いたパスレシーバ選択のモデル構築	62
7.2	選手行動間の予測に基づく因果性分析	62
7.3	仮想環境を用いた視線行動に関する協調パターン獲得実験	63
7.4	協調課題パターンタスクを用いた協調行動の分析とモデル構築	64
第8章	結論	65
	謝辞	67
	本研究に関する発表一覧	68
	付録 A	76

目 次

1.1	各研究のつながりと本研究における方法論	2
1.2	協調的集団行動における概念の共有の概念図	5
3.1	トラッキングデータ可視化ツールの概観	12
3.2	パス行動の分析対象シーン例	13
3.3	ボールホルダーを基準とした全選手の極座標分布	15
3.4	角度重みによって選出された敵味方三人の分布の例	16
3.5	視線重みフィルタ	17
3.6	モデル1のパラメータ行列のヒント図	20
3.7	選手の位置関係による予測の例	20
3.8	シミュレーションの一例	23
4.1	分析の概要	25
4.2	サッカーの動画データ	27
4.3	ハンドボールの試合における集団行動の例	27
4.4	dTEM の構築	29
4.5	パラメータ空間における全選手の各出力分布	30
4.6	dTEM に基づく選手行動間因果性を表現するグラフの構成	32
4.7	分析対象のチームの基本的なフォーメーション	32
4.8	dTEM, dTEM を基にした有向グラフ, 選手の移動軌跡	33
4.9	サッカーの場合におけるパラメータ空間中の全選手の各出力分布	34
4.10	サッカーにおける選手行動間の因果性	36
5.1	分析ツールの概観の例	39
5.2	同期管理リスト	40
5.3	Oculus Rift DK2	41
5.4	実験環境	42
5.5	実験に用いた仮想環境	43
5.6	実験手順	44
5.7	事前・事後での被験者の視線行動の変化	45
5.8	事前・事後での被験者の視線行動の分散変化	46
5.9	攻撃の段階における分散減少の変化	47
5.10	ボールを受ける直前1秒間の視線行動の分散変化	47
5.11	被験者1の視線からの他のFW選手の相対角度	48
6.1	パターンタスク	52

6.2	順方向の行動決定過程	59
6.3	逆方向の他者意図推定過程	60
6.4	他者意図推定における自己優先性	61
6.5	目標パターン到達のステップ数の比較	61

表 目 次

3.1	パス行動分析の一例	14
3.2	分析対象シーンの概略	14
3.3	各モデルの LOOCV 正答率	19
3.4	シミュレーション結果	22
4.1	ハンドボールデータにおける 9 種類のアノテーション	26
5.1	仮想環境の主なパラメータ設定	42
6.1	他者と目標パターンの選択	52
6.2	他者の目標パターンと選択したパターンの関係	53

第1章 序論

1.1 研究背景

複数の人間による協調行動は、個人の能力以上の行動を実現する。例えば、スポーツを見ればチームとして選手がお互いの意図のやり取りを行うことで、柔軟な集団行動を実現する様子を観察することができる。また、日常他の人と協力をする際にも、意識的にせよ無意識的にせよ相手の意図を読み取ることによって円滑な協調が実現されている。しかし一方で、人間の協調的集団行動を実現する個人の意志決定や意図推定についての我々の理解はまだ十分とは言えず、暗黙知的に説明されることが多い。

人工知能の基本問題として1990年認知科学者であるSteven Harnadにより「記号接地問題」[7]が提唱されてから久しく、「記号創発」[49]や「身体性認知科学」[15]の名のもとに、従来の記号論理計算を軸とした人工知能に対する新しい領域として、エージェントが自らの身体を通して周囲環境と相互作用を起こすことで記号や概念、内部モデルを獲得することを重視した研究が多く行われるようになってきている[21, 19]。また、このような創発実現主義の研究は、構成論的な人間知能理解の手法として、認知発達ロボティクスや計算論的神経科学といった領域で盛んに研究が行われている。対人や集団におけるインタラクションにおいても、個人レベルにおける主体の意志決定はその行為主体の持つ概念によって特徴づけられ、経験を通じて得られる他者のモデルを通じて相手の意図が理解される[45, 39, 2]。

また、近年のスポーツにおけるセンシング技術の導入により様々なレベルのデータが獲得されるようになっており、粒度の高いデータが得られる事で、分析の幅も広がっている。詳細な分析を通じて得られる知見を基礎とする事で、人間の集団における認知的な行動の分析への応用が可能となっている。

一方で、人間の言語的、非言語的相互作用を対象とした多人数インタラクションの研究も行われている。多人数による空間的な構造や複数のモダリティによる行動の連鎖など様々な分析的な概念が提案され、実際の会話や競技の分析にも応用されてきており、集団を対象とした研究への関心が高まっている[58, 35]。

本研究はハンドボールやサッカーといったゴール型ボールゲームにみられるような共通目標に対する人間の協調的な集団行動を対象として、集団において共有される概念の利用と獲得を主な研究対象とする。ゴール型ボールゲームは各チームの選手が共通の目的のもと、お互いの意図に基づいて動的に行動を切り替えることで協調を実現する集団行動であり、その集団行動は経験的に獲得された選手同士の共通の合意、概念に基づいて行われると考えられる。近年の情報技術の発展は粒度の高い選手行動データの取得を可能とし、そのようなデータが得られることで、現場の選手および監督の戦術や戦略を支える等、トレーニングや体育学的な教育活動に活用できるのみならず、人間の集団における認知的な

行動の分析に応用することが可能だと考えられる。しかしながら、従来のスポーツにおける選手の行動解析は個人の意志決定の具体的側面やその行動間の関係にまで踏み込むものは多くない。一方で、人工知能や認知科学において個人や対人の行動決定過程には多くの知見が集まってきているものの、集団レベルでの行動を成立する個人の行動、そして行動間の関係といったメゾレベルについては、専門家による経験的な知識のみで、データに基づく定量的な分析およびモデル化は多くは行われてこなかった。

1.2 研究目的及び概要

本研究の目的は、協調目標が明確な集団行動としてサッカーやハンドボールといった実際の集団球技や協調課題を元に分析しモデル化する事で、人の協調的集団行動における個人の行動決定過程を明らかにする事である。人間の集団行動の理解の為に、複数の行動の関係性を捉えた上で、その行動を生成する情報処理のモデルを構築し実際の行動と比較する事で検証を行う必要がある。本研究は図 1.1 に示すように、実試合や行動実験から得られた実行動データを元に、統計量を抽出しそれを分析する分析的アプローチと、内部モデルを構築する事でシミュレーションを行う事で実際の行動と比較・検証するという構成論的アプローチを組み合わせたアプローチを取る。

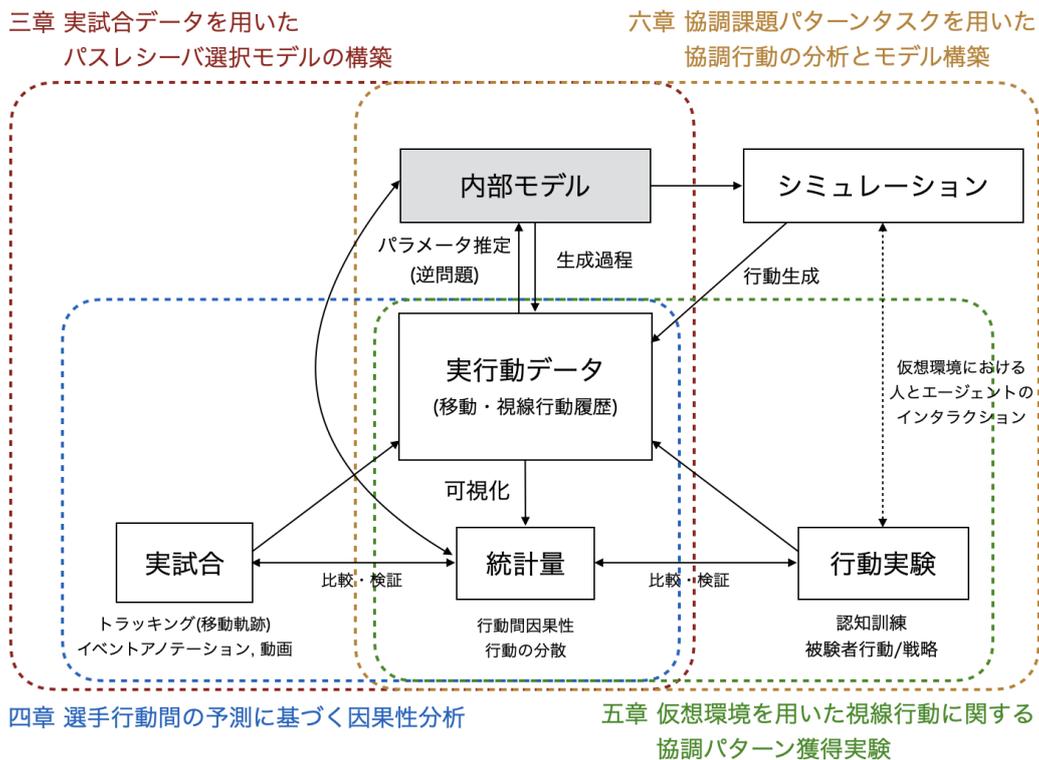


図 1.1: 各研究のつながりと本研究における方法論

本研究は個人の意図をサブゴール、意図に基づいて周囲の状況と行動の関係のパターン

を個人の内部モデルとして考える。そして、同様に集団に対して集団の意図とそこから推定できる集団行動を定める集団等で等しく共有されるものを集団の共有概念と定義した上で、集団球技におけるもっとも基礎的で重要な協調行動であるパスレシーバ選択における行動のモデル化や、情報処理モデルの一側面として行動モデルの構築による実試合データから得られる移動行動の分節化と各集団行動における選手間の行動の切替えの関係を統計量として抽出する。そして、選手の判断が瞬時に現れると考えられる視線行動に着目した行動実験を行い、共有概念が用いられると考えられるパス行動に関する場面の学習による行動の変化の分析を行う。またさらにその内部過程に迫るために、パスなどの目標に基づく少人数の協調行動を抽象化した協調課題パターンタスクを構築し、課題における被験者行動の分析及びモデル化を行う。

ボールゲームにおける集団の目的は、言うまでもなく敵陣のゴールにボールを運び相手のチームより多くの点数を獲得する事にあり、味方との共通認識に基づき相手の攪乱の影響をできるだけ抑えるようにポジショニングを行いパスの連鎖を生成する事が重要である。まずはそのように複数の意図を持つ他者が存在する環境下においてどのように個人の行動決定が行われるのかについて、パスレシーバ選択のモデル構築を行い行動決定において重要な要素を明らかにする。具体的には選手の移動軌跡を記録したトラッキングデータ及び動画データを用いてパス行動を分析し、分析をもとにしたモデル構築を行う。そしてモデルの精度を検証するとともに、さらに実行動が行われるような動的な環境におけるモデルの評価を行うためにシミュレーションを行った。

また本研究は次にゴール型ボールゲームにおける選手位置関係の重要性から、移動軌跡を記録したトラッキングデータから得られる選手の位置やその変化に関する時間的な差異に着目し、集団行動の各場面における選手行動間の因果性を明らかにする。選手行動の因果性を抽出するために、次の二段階のアプローチを取る。まず、選手の移動データに対して隠れマルコフ系のモデルを適用することで選手の位置変化に対するモードの推定を行い離散系列への変換を行う。選手行動は背後に規則性があるものの場面によるゆらぎが大きいため、離散潜在変数系列を扱うモデルが妥当だと考えられる。そして、離散系列となった選手行動の変化点を抽出し他の選手を含めた系列間の関係性を移動エントロピーを用いることで定量的に抽出する。このアプローチにより、選手行動の関係及び各集団行動における各選手の役割を明らかにした。

そして、選手行動として視線行動に着目し、協調を行う特定の場面を繰り返し再現する事による概念の獲得実験を行った。実験では再現性が高く、没入感の高いヘッドマウントディスプレイ (HMD) を用いた仮想環境を用いた。意図共有を行っている状況としてパス行動を含む場面をトラッキングデータを元に再現、選手及び被験者の頭部方向を視線方向の近似として用いる。協調のパターンの学習前後における各場面の視線を分析することで、共有の概念を獲得できるかについての検証を行った。

最後に、共通目標に対する行動決定過程の内部過程を確認するため協調課題パターンタスクを構築して被験者行動実験及び分析に基づくモデル構築とシミュレーションを行う。協調課題において被験者は、小集団での共通目的に対してお互いの行動のみを観測情報として用いる事で、各時点においてどの目標を選択するか、誰に注目して協調をするかを選択を行う必要がある。分析では、被験者の戦略として誰に合わせて行動を行うか、行動決定の際の優先的な行動に着目した。そして分析の結果として得られた戦略を元に、意図推

定と調整のボトムアップの過程と調整の結果として想定される共通目標から考えられる行動決定のトップダウンの過程を持つモデルを構築，それぞれの戦略の差をシミュレーションにより検証した。

本研究は集団における多段階の他者意図推定及びそれを通じた行動決定を明らかにする事を目的としており，本研究の研究成果は次の二点において意義がある。一点目は，集団球技などのスポーツのようなより複雑な集団行動の分析への応用である。本研究の協調課題パターンタスクは集団行動において必要な要素を抽象化し簡略化したものである事から，本研究が明らかとする意図推定の認知過程は集団行動において一般的なものとして応用することが考えられる。また，本研究はサッカーなどのゴール型集団球技を対象とした選手行動決定過程及び行動間の関係に関する分析を行っており，そこで行われる行動決定のモデルや行動間の関係に関する分析を行っている。そのため本研究で得られる成果と合わせて選手の認知過程に根ざした集団行動分析が可能となり，選手行動の予測や弱いチームが強いチームに勝つための新しい戦術の検討に役立てることができると考えられる。さらに仮想環境での協調パターンの獲得に関する研究を通じて，実際の選手の認知訓練やトレーニングに役立てる事も考えられる。二点目は，HAI(Human Agent Interaction) や社会的エージェント・ロボットが集団で柔軟に行動をするための意図推定の方法としての有効なモデルの提案である。特に本研究が対象とする協調的集団の中での人の行動決定過程を再現するエージェントモデルを応用する事で人間を含み支援をするようなエージェントの構築や，人とロボットの共生において人のように他者の意図を推定して自らの行動を変化させるシステムを実現するために，個人や一对一の対人関係とは異なる集団行動における個人の意図推定に関する理解が役立つ事が期待される。

1.3 本論文における用語の定義

本論文で用いる用語の定義を行う。幾つかの用語は定義が研究者により様々であり，一意的な定義は未だ議論されているものも多いため，ここで本研究における意味を限定し定義を明確にする。

- **概念 (Concept)** ... 個体に学習されるパターン。実環境との相互作用による複数モダリティを介した環境から取得される値の変化を対象とし，特に本論文の中では視覚から得られる選手の位置や移動量，頭部方向の切替えによる視線行動といった統計的パターンに限定して分析，考察を行う。人の行動は意志決定やプランニングを支える離散的なダイナミクスと，外界の変化と身体の動きを変化させるといった連続的なダイナミクスの両方を持つ Hybrid Dynamical System(HDS) であり，特に本研究が対象とする随意的な行動は分節構造を持つと考えられる。本研究が概念として捉えるのは，以上のような分節構造に基づく連続的な変化の集まりである。主体内部における分節構造及びパターン間の関係は観測不可能であるが，特に選手行動において他者との行動関係で捉え，実際の場面と照合する事で近似的に推定する。
- **内部モデル (Internal Model)** ... 本論文においては上記の概念と同等の意味で用いる。特に，抽象的な対象ではなく物体のモデル，自己のモデル，他者のモデルとして心的なシミュレーションができるような具体的な対象を想定する。計算論神経

科学の運動制御の文脈で多く研究が行われてきたものであるが、自己だけではなく他者の意図推定なども他者の観測に基づくモデルに沿って行われると考えられる。

- **意図 (Intention)** ... 各場面における個人の行動を生成するサブゴール、より具体的にはサブゴールにおいて出力と入力に対応関係を切り替える関数として扱う。目的が明示的に決まっている場合には、同一の状況において出力される行動の差異は、意図の異なりと解釈する事もできる。対人、集団における意図に関して、個人の内的な意図よりむしろ高梨 [55] が指摘する観測され他者に解釈されるような「リソースとしての意図」に本研究は着目する。すなわち、他者の誤った解釈を許容する立場を取り、たとえ行動を行った者の意図とその行動の影響を受けて行動を切替えた者が推定した意図が異なった場合にも、相互作用の結果を行為者に帰属する。特に、自分の行動と他者へのその解釈を想定した観測される随意的な行動が集団行動において協調を成立する為に重要である。

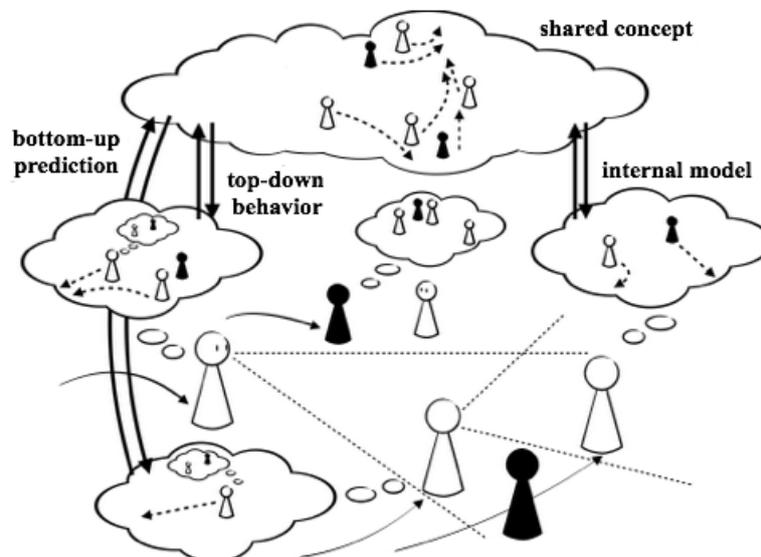


図 1.2: 協調的集団行動における概念の共有の概念図

- **協調パターン (Cooperative Pattern) / 共有概念 (Shared Concept)** ... 集団の意図の集合とそこから推定できる (集団) 行動を定める内部モデル。周囲の状況において行動を決定する場合の、自分を含む集団の HDS を想定する。例えばボールゲームにおけるパス行動を例に取れば、パスを実現する為には、選手同士でお互いのモデルを内部モデルとして獲得する事で相手の動きを予測する事が必要である。図 1.2 のように、ボトムアップ的に各個人の意図推定や意図の調整を行い、またトップダウン的に行動決定に関係する、経験的に獲得される集団での概念を本研究における共有概念として定める。

1.4 本論文の構成

本論文の構成は以下の通りである。

第二章では、本研究の関連研究について、特に本研究と関係する人間及び機械の概念及び内部モデル獲得に関する研究、スポーツにおける数理的研究、そして集団を対象とした多人数インタラクションに関する研究の概要を説明し、本研究との関連からまとめる。

第三章では、実試合データに基づくサッカーエージェントのレシーバ選択モデルの構築について述べる。人の協調的集団行動の例としてサッカーの中でも最も基礎的で重要な行動であるパス行動に着目し、複数の意図を持つ他者が存在する環境でいかに意思決定が行われるのか、またボールホルダーとレシーバの関係という個人レベルの関係からどのように集団レベルの行動が創発するのかを明らかにした。

第四章では、ゴール型ボールゲームにおける各集団行動内での選手行動間の予測に基づく因果性分析の手法を説明する。そして、ハンドボールとサッカーのデータを用いて行った行動モデルによる選手行動の分節化と行動間の関係の分析について述べる。

第五章では、動的環境下における選手の参照行動として視線に着目し仮想環境を用いた概念獲得実験について述べる。人の集団行動は時空間的に動的に変化する環境においてお互いの意図を推定もしくは表出し、自らの行動を柔軟に変化させる必要がある。そのような複雑な意図の共有を実現するものとして本研究は協調のパターンが集団行動の参加員の中で共有され、そのパターンに基づいて行動を行なっていると仮定し、そのようなパターンがどのように獲得されるのかを仮想環境を用いた被験者の視線行動から分析した。

第六章では、協調課題パターンタスクを用いた他者意図推定を含む行動決定過程のモデル構築について述べる。人の協調的集団行動における他者の意図推定を含む行動決定過程を明らかにするため、複数人がお互いの意図推定を行いながら共通の目標を動的に切り替える、二次元上の協調課題を構築し実施する。課題における被験者の行動及び意図推定の深さについて分析し、さらにエージェントモデルの作成及びシミュレーションを行う事で、被験者の目的の決定と意図推定に関する協調戦略の差異を明らかにした。

第七章では、本研究における各々の研究で得られた結果に関する総合的な考察をし、今後の展望を述べる。

第八章では、本研究の総括と今後の展望を述べる。

第2章 本研究の位置付け

本章では、関連する研究をまとめる事で本研究の位置付けを明確にする。特に、人間個人の情報処理に関する計算論的アプローチに関する研究として、認知や神経科学と連携して行われている研究、今回本研究が対象としたようなボールゲーム等のスポーツを対象とした数理的アプローチに関する研究、最後に社会学的な基盤を持ちながら技術の発展により可能となった近年注目されている人間集団を対象としてその相互作用を分析する多人数インタラクションの研究について説明する。

2.1 人間・機械の概念, 内部モデル獲得に関する計算論的アプローチ

2.1.1 概念, 内部モデルの獲得

人工知能, ロボティクスと概念獲得の問題は90年のHarnadの記号接地問題[7]と関係し, 自らの身体に基づく知覚・運動を通して環境と相互作用をする事により概念や内部モデルを獲得し用いるという研究が多く行われている。また, それらの研究は人に学ぶ知覚的情報処理の実装を目指す工学的な側面を持ちつつ, 創る事により, また創れる程に人間の知能を理解しようという理学的な側面を合わせ持つ。

川人らはMarrの, 複雑な知覚的情報処理システムを理解するための三つのレベル[24]の考え方に基づき, 環境を予測する順モデルと, 各状況において最適な制御を生成する逆モデルの両方の組み合わせを持つ内部モデルを提唱した[41, 21]。Marrの三つのレベルは, 情報処理を行う目的や方略を定める『計算理論 (computational theory)』のレベル, その方略をどのように実現するかを定める『表現とアルゴリズム (representation and algorithm)』のレベル, そしてそのアルゴリズムを物理的な形でいかに実現するかという『ハードウェアによる実現 (hardware implementation)』のレベルに分かれ, その三つのレベルのお互いの制約を考慮しつつ実現する事の有用性を述べている[24]。川人は人間の運動制御のモジュール性に着目し, Wolpertと共に運動制御を実現するMOSAIC (the Modular Selection and Identification for Control) モデルを考案し, その上で実機のヒューマノイドロボットへの実装を行い30種類以上の運動の学習に成功している[42]。さらに, 順逆モデル及び予測に伴うフィードバック誤差の値の変化と生理学・解剖学的データを照合する事で内部モデルが小脳で獲得される事を主張している。また, 強化学習とMOSAICに基づく内部モデルの階層的獲得を組み合わせる事[6, 40]や, 内部モデルをシンボルとして用いる事による二者間でのコミュニケーション等の研究も行われている[43]。

谷らも同時期から内部モデルを再帰型ニューラルネットワーク (RNN; Recurrent Neural Network) を用いた力学系により表現するモデルを考案しており, 柔らかい分節化を時間の異なるネットワークを用いて表現できる事を示している[19, 23]。また, 稲邑や高野ら

のミメシス理論に基づく行動の認識と生成を可能とする HMM を用いたモデル [9, 33], 谷口らの Piaget のシエマ理論に基づき知覚と行為を分節化する事が可能な双シエマモデル [52] も, 分節化に基づく概念, 内部モデルの獲得という点で共通した計算理論に基づく研究が行われている。

こうした分節化を通じた内部モデル獲得の仕組みは, 人間行動の分析にも活用する事ができ, 行動時系列分節化には様々な行動を対象とした数多くの研究事例がある [51, 53, 27, 44, 61]. また, 人間の high-order 認知を伴う情報処理といった外部から観測できない対象について, 観測データから説明される構造を基に推定ができる点でモデル的解釈は有用であり, 本研究も実試合データからボトムアップに考えられるモデルを基に行動, また行動間の関係を捉える。

2.1.2 協調の計算モデル

協調行動に関するマルチエージェントの研究でも分節化の問題は重視される。野田は個人レベルでの行動のモデル化による模倣学習を, 協調行動にも応用している [59, 60]. 複数の HMM を階層上に組み合わせる事で, 行動の切替えをエージェントの意図に基づくとしてエージェント間の意図のインタラクションのみを考える事で次元の削減を行っている。またモデルを基にシミュレーションを行うことで協調行動が学習される事を示している。行動の切替えの基礎として意図を仮定する事は本研究も同一の立場であり, 人の協調をマルチエージェント系で考えた場合の状態の組み合わせによる計算量の問題をどのように解決するのかという事に関して示唆に富んでいる。

一方, HAI の立場からはエージェントの社会性が強く要請されている。特にエージェントと人間の協調を考えると, 他者の意図の推定が課題となり, 他者を動的な概念として獲得し, その振舞いを予測することが必要となる。主体の振舞いと他者の意図の読みの深さをシミュレーションにより分析する研究も存在する。横山ら [29, 28] は協調行動における心の理論を強化学習モデルを用いることでモデル化しシミュレーションを用いた分析を行っている。行動決定モデルを階層的に, Lv.0 「他者の意図推定など行わず自分の目標に向かって突き進む」, Lv.1 「他者の行動から意図を推定し, それに基づいて自分の行動を決定」, Lv.2 「他者の意図推定, 他者から見た自分も推定し, 行動を決定」, Lv.0* 「自分の意図を決定, それを明示的に相手に伝えて誘導 (能動的戦略)」といった意図推定の再帰レベルを仮定しどの段階のエージェント同士が最も協調的にタスクをこなすことができるのかについて, 単純なグリッドワールドを用いて説明している。また, 上段らも同じく意図推定の再帰レベルを想定し, 多人数でのすれ違いのシミュレーションに HMM を用いて検証を行っている [39]. そして, Baker らは行動から推定される意図をベイズモデルによる推定と実際の人間の推定とを比較し, 心の理論の計算モデルの有効性を確かめている [2].

意図推定の再帰レベルは高梨 [55] が指摘するような, 自分の行動の意味を他者に理解させるメタレベルの意図を考える上で重要だと考えられる。すなわち, 他者にとって多義的に解釈され得る行動を, 経験を通じて共通の理解を可能にするような概念を通して理解し理解させる事が集団としての柔軟な協調行動に必要な不可欠であろう。

2.2 スポーツにおける数理的アプローチ

スポーツを数理的に扱う研究は1950年代にまで遡ることができる。野球において、古くからOR(Operations Research)研究の一貫として、得点に関する要因をモデル化する研究が多い。鳩山[57]は、野球をデータから確率モデルの一つであるマルコフモデルで記述し、盗塁やバントを行うべきか、またどのような状況で行うかについて考察をしている。また、鳥越[54]はモデルを構築するだけにとどまらず、モンテカルロシミュレーションを行うことで野球における最適打順をランキングで表現している。山口[37]が指摘しているように、野球はもともと得点を記録する習慣が根付いたスポーツであることや、攻撃と守備が特定のタイミングで完全に切り替わる為それぞれの状態を切り分けやすいことが、古くから数理的なモデリングが多く用いられてきた理由であると考えられる。山口ら[37]はバスケットボールにおける「ディフェンス力」をリアルタイムで記述するために、先述したOR研究と同様に「ボール保持」、「ターンオーバー」、「シュート」等と各状態を離散化してその関係を数理的に記述している。

一方、スポーツの現場で実際に指導をするために数理的なモデルを用いている研究も存在する。例えば大西[46]らは小学校のバスケットボール授業において教師が指導する時に用いる指標を得る為に、重回帰分析によって特定の状態同士の関係を数値化している。また横山[30]らはホッケーにおけるダイナミクスをエントロピーを用いて記述することで、個人の勢力範囲を”圧場”と定義し、その集合である”チーム圧場”の時間的変化のダイナミクスを分析することで競技の性質を明らかにしている。ただ、これらの研究は統計的な手法による集団レベルでの分析であり、個人レベルの意思決定を取り扱っていない。他にもスポーツに関する研究としては、高橋ら[32]や瀧ら[48]のような映像を用いた視覚化の研究が行われているが、これらの研究は手法の作成にとどまっている。

また、近年の情報技術の発展により位置の軌跡を記録したトラッキングデータや視線データ、各所選手の心拍や血糖といった生体データが得られるようになって来ておりデータ分析の幅を広げている。特に軌跡データを用いた集団行動認識の研究も行われ、隠れマルコフモデル(HMM)系統のモデルをカップリングする事や階層的な手法を用いて動的な構造をモデル化し、軌跡パターンから集団行動をマイニングする研究が進んでいる[3, 8, 18]。それらの研究は本研究との類似性があるが、本研究の動機は集団行動を予測することではなく、選手の間関係を抽出し、それを個人レベルの意志決定の解釈に用いる事で異なる。

2.3 多人数インタラクションに関する分析的アプローチ

会話分析と情報学の融合の流れから、人間集団の言語的・非言語的相互作用を対象とした『多人数インタラクション』の研究も広まりつつある[58]。会話分析等の社会的相互作用に関する研究は60年代から既に行われているが[31, 12]、近年の情報技術の進歩により様々なセンサを通じたデータが獲得されるようになった事から、多様なモダリティを介した現実的で複雑な場面を直接分析する事が可能となって来た。

高梨らは会話分析におけるジェスチャー単位、また自身によって考案した「他者の認知の利用」といった概念をサッカーに適用し分析を行っており、選手の志向が行動によって他の選手に観察可能である事を重要視しており、選手の身体を無視した還元論的アプロ

チの批判を行っている [36, 34]. 選手の身体レベルの微視的な分析の重要性については基本的に高梨らと同じ立場であり, 統計的パターンを抽出するだけに留まらず, 相互作用を行う選手の視点に立ち返って分析する事が集団における個人の行動理解のために必要だと考えている.

一方で分析には緻密な現象の記述が必要であり, 緻密な分析の中で現象の様々な側面に気づく事ができるという利点は存在する一面, 分析対象が多ければ多くなるほど人手でのアノテーションは困難か, もしくは不可能になってしまう問題を抱えている. これに対し数理モデルを用いた研究も実際に行われており, 会話における視線の分布構造の推定に用いられている [47]. 多人数インタラクションのような集団の複雑な相互作用を理解する上では, 緻密な分析に加え, 統計や機械学習技術を利用した分析, または仮説に基づくモデル構築による構成論的な検証の繰り返し, 両者を相補的に行う事でこれまで以上の知見が得られる事が期待される.

第3章 実試合データを用いたパスレシーバ選択のモデル構築

3.1 実試合におけるパス行動の分析

3.1.1 分析の目的

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らず、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。本章では、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。さらに仮想環境である Robocup 2D Simulation を用いてレシーバ選択モデルの動的な環境における有効性の評価を行った。

3.1.2 分析対象

分析対象は、データスタジアム株式会社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。

3.1.3 分析手法

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。

次に、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3.1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

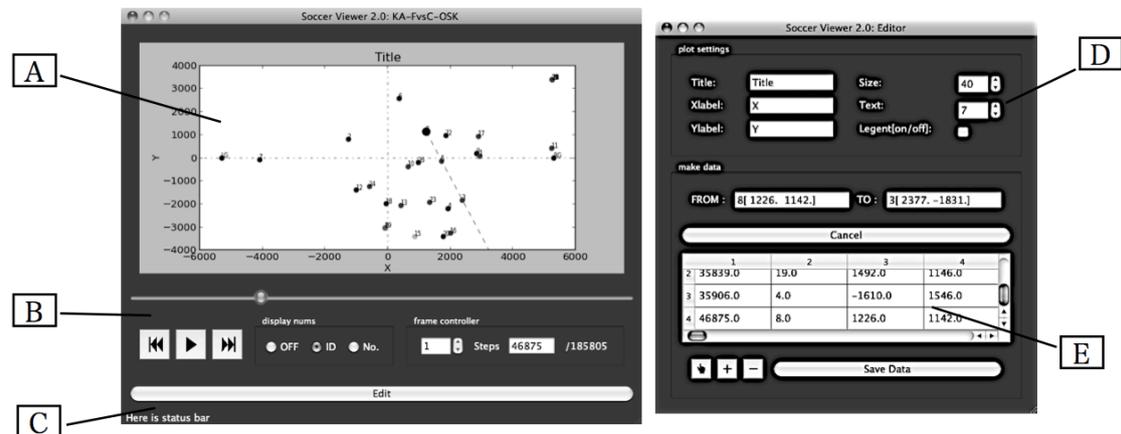


図 3.1: トラッキングデータ可視化ツールの概観 (左:メインウィンドウ, 右:編集ウィンドウ)

- 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)
 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)

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 3.1-A). また, コントロールパネル (図 3.1-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 3.1-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 3.1-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 3.1-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. 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, グラフの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.

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, そ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 3.1), 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、マークをされるといった、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3.1と図3.2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3.1はその抽出結果の一部となっている。また、表にある内容が実際の試合でどのように起きているのかを、概念図として図3.2に示した。

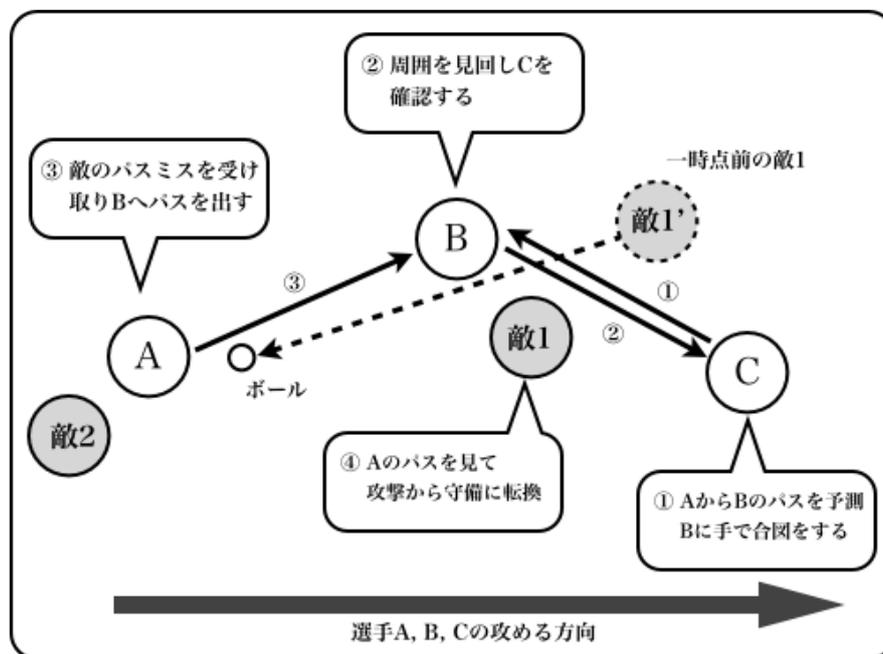


図 3.2: パス行動の分析対象シーン例

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秒間の記述における、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。

3.1.4 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。表3.2に分析に用いた各シーンの概要をまとめた。シーン1では、味方4人、敵2人の選手がパス行動に関係している。パスミスを奪った選手が、あ

表 3.1: 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

らかじめ意図を共有していた二人の選手にパスをつなぐことで, その二人を介する連続したパスから攻撃的な展開が始まる. そこから縦方向へパスを展開してからシュートをするまでの流れとなっている. シーン 2 では, 味方 5 人, 敵 2 人を含めたパスシーンで, このシーンでも敵のボールを奪った選手が, 縦方向にパスを繋いでいくことで攻撃的な展開を作っている. シーン 3 では, 味方 4 人で各選手が別の選手の意図を推定しながら縦方向に連続的なパスによる攻めを見せている. このシーンでは敵選手は単にボールを奪い返そうとするのみで, パスをしていく選手に対する意図推定を含む行動を観測することができなかったため含めなかった. シーン 4 では, 選手が敵味方混在している状況からパスを送り, 選手同士でパスを繋いでいくシーンとなっており味方 6 人, 敵 2 人が含まれている. 最後のシーン 5 では, 味方 3 人, 敵 1 人で, 敵選手のボールを奪う場面から始まる連続パスによる攻撃的な展開である.

なお, 各分析の詳細については付録 A を参照されたい.

表 3.2: 分析対象シーンの概略

各行はシーン番号, フレーム, パス行動に関係する選手人数(味方/敵), シーンの概要

Scene	Frames	Players	Outline
1	8214 - 8457	6 (4/2)	敵のパスカットから縦方向への突破後シュートまで
2	17021 - 17430	7 (5/2)	縦方向への突破からシュート (早い展開)
3	17778 - 17994	4 (4/0)	縦方向へのボール流しからシュート
4	35427 - 35809	8 (6/2)	縦方向への突破からシュート
5	69161 - 69477	4 (3/1)	敵を抜いてゴール

分析の結果、5シーンにおけるすべてのパスにおい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シーン中6シーン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分布をグラフ化した。図3.3に分析結果の一例を示す。

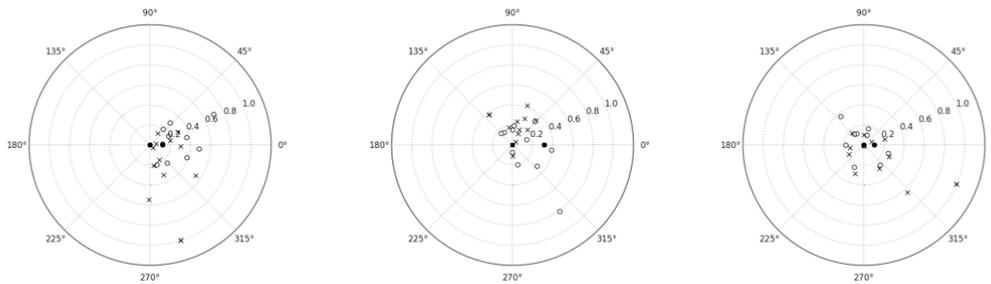


図 3.3: ボールホルダーを基準とした全選手の極座標分布

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)

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3.3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3.3右)である。第一のタイプでは、一番近い味方選手をレーバーとするものと(図3.3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ーバーとするもの(図3.3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3.3右)。

3.1.5 分析の考察

ボールホルダーが敵の分布に基づきレ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3.4)。結果、分析中のす

べてパス行動において上記のような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ーバーが味方選手三人以内に収まることが確認された。

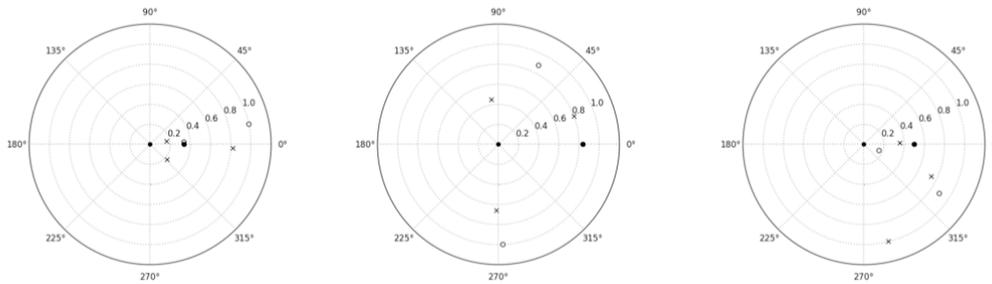


図 3.4: 角度重みによって選出された敵味方三人の分布の例

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)

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ばられてしまい、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 [22]。加えて、実際のサッカーにおいてもフォーメーションの構築は、人と人を線で結んでできる三角形を基本として作り上げるといふ [38]。それゆえ、三人を対象とすることは最も妥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 3.4 下の分析結果から、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。

3.2 パス行動モデルの構築

3.2.1 モデル構築の目的

3章ではサッカーにおける人間のパス行動を分析し、パス行動に関係する敵及び味方選手の位置や、視線による選手の分類が重要であるとの結果を得た。本章では、分析によって得られた仮説を基にモデルを構築することで、その仮説の妥当性を検証するとともに、モデルを利用することによってパス行動に関係する選手間の距離及び角度といったパラメータの解釈を行う。

3.2.2 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、出力に対する不確か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。

3.2.3 入力データとパラメータの学習

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以外の二試合のデータも含めてサンプルデータとし、100個分のパスシーンのサンプリングを行った。

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3.5の視線重みフィルタを用いた。

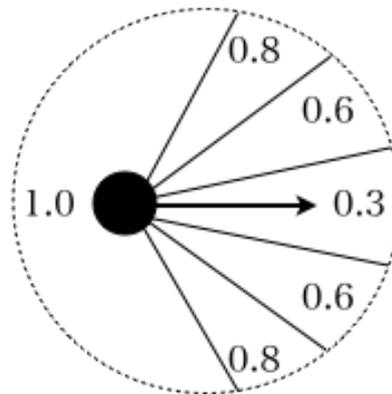


図 3.5: 視線重みフィルタ

図3.5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、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たため、考慮される味方選手の一人とした。

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ど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 (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 (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 (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.

$$y = \sigma(\mathbf{w}^T \mathbf{x}') \quad (3.1)$$

$$E_n(\mathbf{w}) = -\{t_n \ln y_n + (1 - t_n) \ln(1 - y_n)\} \quad (3.2)$$

$$\mathbf{w}_{new} = \mathbf{w}_{old} - \eta \nabla E_n(\mathbf{w}) \quad (3.3)$$

(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. (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(2)が多クラス交差エントロピー誤差関数となる. (3)における η 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.

3.2.4 モデルの評価

4.3.3項で述べたそれぞれのモデルについて, LOOCV(Leave-one-out Cross Validation; 一つ抜き交差確認)を用いて正答率を算出した(表3.3).

< 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

表 3.3: 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%

- 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。

モデルの考察: 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。

モデルの考察: 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 3.6 はモデル 1 におけるパラメータ行列のヒント図である。

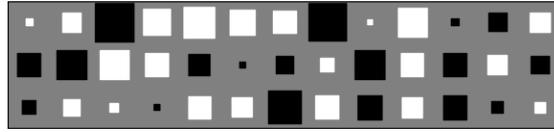


図 3.6: モデル 1 のパラメータ行列のヒントン図
(白が正值, 黒が負値, 最大値が 1 となるよう正規化をしている)

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 3.7 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 3.7 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ることで、その選手が選ばれることが予測される (図 3.7)。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バを正しく予測できると考えられる。

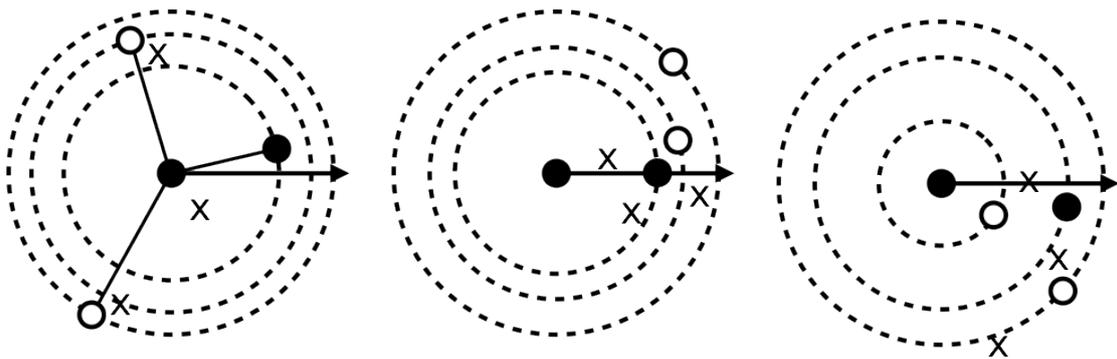


図 3.7: 選手の位置関係による予測の例
左: 一番目の味方選手が選ばれる状況
中央: 周囲に敵が集まっている状態でボールを出すパターン
右: 敵や味方が混ざり合っている状況でボールを出すパターン
(白丸が味方選手, 黒丸がボールホルダーとレーバ, 敵が×印でホルダーの視線方向を矢印で表す)

3.3 シミュレーションによるモデルの評価

3.3.1 シミュレーションの目的

ここでは第4章で構築したパス行動モデルを、コンピュータ上の仮想環境で再現する。モデルを用いたシミュレーションを行うことで、単にモデルを構築するだけでは得られない、動的な環境におけるモデルの実時間での振る舞いを観察し評価することができる。以下では、実際にモデルのシミュレーションを行った結果及び考察について述べる。

3.3.2 シミュレーション

シミュレーション環境としてロボカップ2Dシミュレーションを用いる。ロボカップサッカーシミュレーションリーグは人工知能分野におけるマルチエージェント研究のテストベッドとして1996年から用いられている。

サッカーシミュレーターはクライアントサーバーモデルを利用しており、物理エンジンを備えてフィールド上の物理演算を行うサーバー (rcssserver)、フィールドの状況を描画するモニター (rcssmonitor) 及び各プレイヤーエージェントプログラムを実行するクライアントに分かれる。通信は通常1秒間に5回 (20msごと) に行われ、サーバとクライアントが文字列を送り合うことで行われる。

2DリーグはX-Y平面のフィールドで両サイド11体ずつのエージェントが前後半5分ずつの試合を行う。なお2Dリーグにおいて高さの概念は存在せず、ボールや選手が宙に浮くことはない。

モデルの実装

モデルの実装に際して次の三つの段階でシミュレーションを行う。

1. ボールホルダーのみがモデルを実装する。
2. ボールホルダーの周囲のレシーバ候補となる選手がモデルを持ち、ホルダーの意思決定を推測する。
3. ボールホルダーの周囲のレシーバ候補となる選手がモデルを持ち、ホルダーの意思決定を推測する。ホルダーはモデルによって算出されるパス経路をゴールまで拡張し、最適レシーバを探索する。

シミュレーション1では、モデルをボールホルダーのみに実装し、モデルによって予測される三人の近隣の味方選手に対する確率の最大値が一定の閾値を越えた場合に最大の確率値を持つ味方選手にパスを行うようにした。

シミュレーション2ではボールホルダーのみならず、味方選手がモデルを持つことでホルダーの意図を推定し行動する。レシーバに選ばれた選手の行動はボールホルダーを中心とする円を数分割し、敵の選手が入っていない扇形領域を目的地点として移動するようハンドコーディングを行った。

モデルによって推定される経路はホルダー1人に対して近隣の味方選手3人という一次的な繋がりのみだが、シミュレーション3ではその経路を元にレーバーとなる選手を推定し、再帰的にゴールまで計算することで、大局的な意思決定が行えることかどうかを確かめる。今回は、ホルダーによって最も高い確率で推定されたレーバーに対してモデルによる推論を繰り返し、最大で深さ4回でゴールに到達する最大の確率値を持つ経路を最適経路として探索する。最適経路の確率は全体の経路の確率の積として表し、パス行動を決定する閾値についても経路の深さの分累乗した。

なお、本研究においてシミュレーションプログラムは秋山 [26] の公開しているプログラムソース (agent2d) を利用する。基本的に、各段階のパス行動の意思決定に当てはまらない場合はこのベースソースに基づいた行動を取る。また、モデルに基づく意思決定や意図推定に用いるホルダーの視線は、エージェントが狭い視野を補うために常に首を振り続けることで、実際の人間の場合と乖離するため、擬似的にエージェントの速度ベクトル方向を視線方向とした。このベースチームとモデルを実装した各段階のテストチームを対戦させることでモデルの評価を行う。

3.3.3 シミュレーションの結果

シミュレーションはそれぞれの段階について1ハーフ3000サイクルの試合をそれぞれ55回づつ行った。また、ボールホルダーのパスを決定する閾値は、全ての段階で味方選手に対する確率の最大値が95%を越えた場合とした。

表 3.4: シミュレーション結果

	段階 1	段階 2	段階 3
平均得点	0.76	0.57	0.18
平均失点	2.72	2.63	2.87
全体平均パス回数	196.56	180.87	193.89
パス成功回数 (平均, 標準偏差)	73.75(s.d. 12.15)	64.85(s.d. 12.00)	66.09(s.d. 9.51)
パス失敗回数 (平均, 標準偏差)	30.69(s.d. 5.37)	29.70(s.d. 5.48)	33.64(s.d. 4.16)
平均モデルパス成功率 (平均, 標準偏差)	67%(s.d. 23%)	60%(s.d. 24%)	65%(s.d. 15%)
全パス中モデルパス率	26%	25%	39%

表 3.4 の結果から、平均得点は段階を減るに従って減少し、失点も大きくなっている。全体の平均的なパス回数としては段階2のみ多少下がり、他はほぼ同じ結果となっている。また、モデルパスの成功率を見ると全体として6, 7割程度で、段階別に見ると2が下がり、段階1と3がほぼ同じ値となっているが、段階3の方が標準偏差が減っている。

3.3.4 シミュレーションの考察

仮説としてはシミュレーション1から3に変化するにつれ、局所的意思決定のみからゴールに着目した大局的な意思決定に移行することで得点の伸びが期待されたが、結果としてそれに反する形となった。モデルに基づくパスは6, 7割程度成功しているため、得点に繋がる場面で点を入れられていないことが伺える。失点が増える理由は段階を減るに

従いレーバーは強くゴールを意識した形で行動を選択し、ポジショニング等の守備に必要な行動が疎かになったためであると考えられる。

また全パス中のモデルパスの数が段階3でもっとも多くなったのは、ホルダー及びレーバーが常にゴールを意識した意思決定をする為、モデルの予測に当てはまるパターンを増やすことができたためであると考えられる。それでもパス成功率が下がってしまうのは、動的環境においてホルダーがベストだと推測してボールを送る地点と、レーバーがホルダーの意図を推定して移動する地点にずれが生じた為であると考えられる。さらに、シミュレーションの試合を確認したところ、ゴールとの距離が非常に離れているにも関わらず、ゴールを選択するシーンも見られた(図3.8)。これは、エージェントがその場でゴールをパスする対象として計算した推定値が、自身のキック力というような物理特性と、将来の敵の位置というような未来の状態を考慮できていない為だと考えられる。4章でのモデル評価のような静的な状態におけるパス予測と異なり、動的環境における状態変化を今回の実装では扱いきれなかった可能性が考えられる。

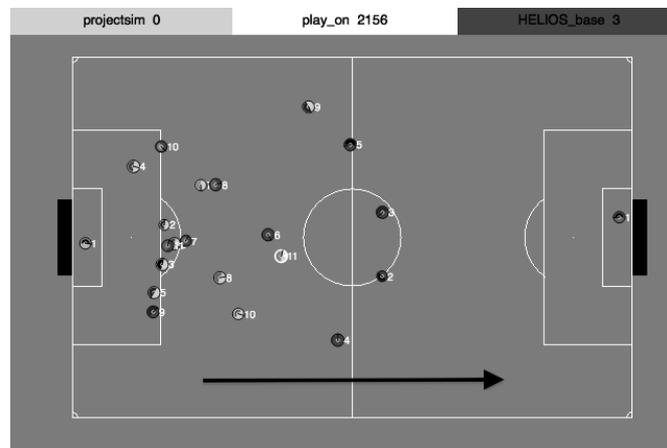


図 3.8: シミュレーションの一例
11番がシュートを選択している(矢印が攻めている方向)

3.4 今後の課題

静的な状態における本モデルの予測精度は非常に高かったものの、実際にシミュレーションをすることで動的環境における問題が浮き彫りになった。一つ目は、レーバーがホルダーからのパスを受ける為にスペースに移動することは、ホルダーの推定して実際にパスをした段階の位置からはずれてしまう事である。もう一つは将来の選手の位置変化を考慮できていない為にパスカットを確実にされうる状況でもパスを選択してしまうことである。

今後の課題としては閾値パラメータの調節及び実装の仕方、特に動的環境を考慮したモデルの組み込みを再検討する必要がある。シミュレーションにおけるモデルの実装としても今回は味方チームの攻撃パターンとして利用したが、敵チームのパス予測モデルとして守備に持ちこることも考えられる。

また、パス行動モデルとしてもいくつか課題が残っている。本研究においては、人から人のパスのみをモデル化したが、実際には選手ではなく、選手前方のスペースにパスをする状況も多く見られる。これは将来のレーバーに対する予測と考えることで、人から人へのパスの枠組みで考えることができ、本モデルを用いて将来の選手位置関係を入力とした推論が必要となってくる。これら状況の動的変化への推論の拡張は今後の課題となるだろう。さらに、視線に対する重み付けフィルタは今回恣意的に選択したが、それらの値についても検討する必要がある。加えて、今回は分析やデータの切り出しを実際に試合を目で確認しながら行ったが、さらにデータを大量に獲得する場合は選手の行動や視線方向等を自動的に切り出すシステムが必要となるだろう。

3.5 結論

本研究ではパス行動におけるミクロレベルの意思決定モデルから創発するマクロレベルの戦術的集団行動を理解するという目的の元、サッカーにおけるパス行動の分析からモデル化、シミュレーションまでを行った。実際のJリーグの試合における選手の意思決定や意図の共有を詳細に分析し、パス行動の状況が周囲の敵や味方の位置関係によって分類できることが分かった。また分析したシーンから、パスの対象となる選手をボールホルダーの視線に基づいて予測できることが仮説として得られた。

次に、分析から得られた仮説を検証する為、ロジスティック回帰モデルを用いた多クラス分類としてボールホルダーのパス行動の意思決定をモデル化した。複数のパスシーンを教師データとして学習することで、仮説に基づくレーバ選手の選択が高い精度で行えることを示した。

最後にロボカップ2Dシミュレーション環境を用いて、モデル実装を行い、各モデルのリアルタイムでの振る舞いを評価した。モデルの実装は次の三段階を行った。一つ目は、ボールホルダーのみにモデルを実装し、パス対象となるレーバーをモデルの推定確率値に基づいて決定するよう実装した。そして二つ目では、ホルダーは同じくモデルに基づく意思決定をし、ホルダーの周囲のレーバーがスペースへ移動するよう実装した。最後の三つ目では基本的なホルダーとレーバーの行動は二つ目と同様だが、推論の際に局所的な選手の位置関係ではなく、ゴールにまで拡張した推論を行うよう実装した。シミュレーションにおいてはモデルの推定が動的な環境にうまく対応できないという課題が残った。静的な状態から、将来の入力を予測するといった、より動的な状態変化を仮定した意思決定や意図推定を行うことでさらに改善することが考えられる。

4.2 分析対象

分析対象としてハンドボール及びサッカーの実試合データを用いる。具体的に、ハンドボールのデータとして CVBASE06 handball video dataset[14] を用い、サッカーのデータとして FIFA Confederations Cup 2013 年のスペイン対イタリア戦のデータを用いる。

CVBASE06 は Pers らが無償で提供しているデータセットで、ハンドボールやバスケットボール、スカッシュといったスポーツの動画画像や、選手位置のトラッキングデータが含まれている。今回分析に用いるハンドボールのデータセットにはハンドボールの10分間のモデル試合における動画画像データ、トラッキングデータ、集団行動のアノテーションデータが含まれている。動画画像データ、トラッキングデータは共に 25fps で記録されており、トラッキングデータは片方のチームの7人の選手のXY平面上の軌跡のみが記録されており、もう片方のチーム及びボールの座標は含まれない。またアノテーションデータは、動画画像に見られる集団行動を9種類のラベル(速攻、守備のセッティング、ゴールに絡む攻撃等)に基づき、一人のコーチの判断により1秒ごとに記録したものである(表4.1, 図4.3)。

表 4.1: ハンドボールデータにおける9種類のアノテーション

Annotation	Meaning
ovpp	defense, returning, preventing fast break
ovpc	defense, slowly returning
obg	defense, basic defense, defense against preparation of an offense
obz	defense, basic defense, defense against ending offense
t	break or time-out
nks	offense, fast break
nfpn	offense against set-up defense, setting up an offense
nfan	offense against set-up defense, ending an offense
npp	offense, slowly going into offense

スペイン対イタリアの Confederations Cup のデータは、30fps で記録された試合動画画像データ及び 10fps で記録されたトラッキングデータが含まれている。試合動画画像データは固定カメラによる俯瞰的な構図となっており、図4.2のようにフィールド全体が一望できるようになっている。また、3840 x 2160 の高解像度により収録が行われているため、フィールド上の選手の向いている方向等を確認することができる。トラッキングデータはハンドボールデータと異なり、フィールド上の両チーム全ての選手及びボールの座標が含まれる。サッカーのデータにはアノテーションデータが含まれないため、前半十分間に関してハンドボールと同様の攻守の序盤や終盤に基づく基準で自らラベル付けを行った。

4.3 分析手法

今回の分析では、時系列分節化の為に隠れセミマルコフモデル (HSMM; Hidden Semi-Markov Model), 系列間の関係を抽出するために時間遅れを含むトランスファー・エント

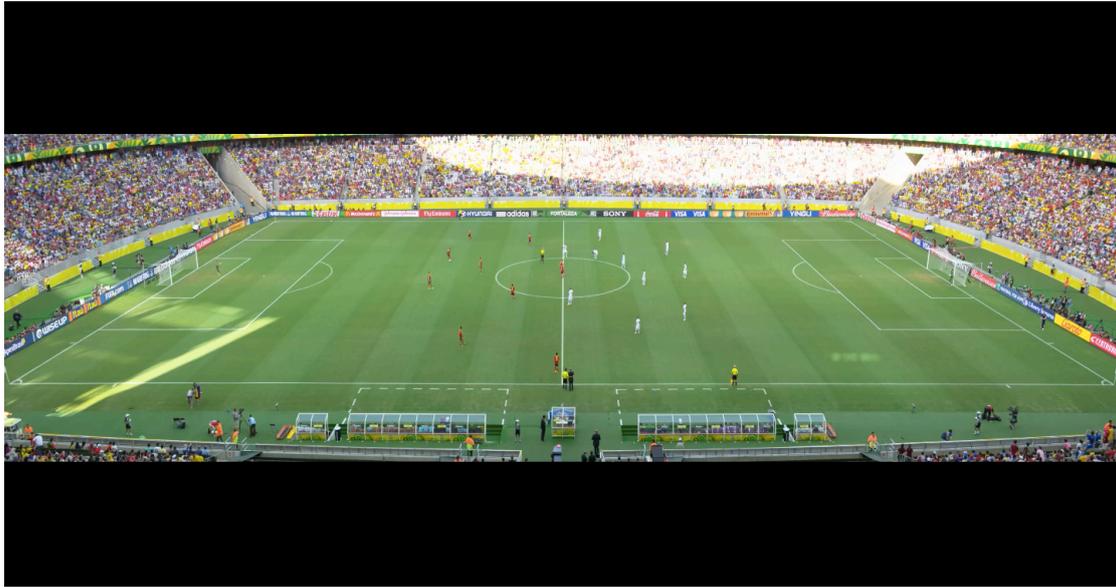


図 4.2: サッカーの動画データ



図 4.3: ハンドボールの試合における集団行動の例. それぞれの集団行動は色付きのユニフォームを着用した選手の視点で記述される. (a) nfan; ゴールに関する攻撃の終盤. (b) nks; 速攻. (c) obg; 通常の守備の序盤

ロピー (dTE; delayed Transfer Entropy) を用いた. HMM やその亜種の系列モデルは時系列における状態の切り替えを柔軟に表現できることから人間やロボットの行動のモデル化や分節化においてよく用いられる [9, 50, 61]. 時系列を扱う他のモデルとして RNN やカルマンフィルタ等も考えられるが, 前者に関して決めるべきパラメータが不必要に膨大な量になってしまうことや, 後者に関して潜在変数を連続値で扱うことは今回の目的にそぐわない. HSMM の利点として教師なし学習が可能かつデータに対するモデルの当てはまりを統計的に評価することができること, さらに分節化の際に観測データの継続時間や前後関係といった時間的な性質を考慮することができることが挙げられ, 本研究のトラッキングデータの分節化に妥当であると考えられる. また dTE は符号列の情報の流れをモデルフリーで計ることができるため, 今回の分析に適していると考えられる.

4.3.1 選手の移動行動モデル

HSMMは離散値または連続値の観測系列がマルコフ性を持ち、遷移する潜在変数から逐次出力される生成モデルである。長さ n の系列に対して潜在変数 $x_{1:n} = (x_1, x_2, \dots, x_n)$ 、観測変数 $y_{1:n} = (y_1, y_2, \dots, y_n)$ 、初期状態確率 ρ 、状態遷移確率 A 、出力確率 O によって定義される。

$$p(\mathcal{X}, \mathcal{D}, \mathcal{Y}) = p(x_0)p(d_0) \prod_{t=1}^T p(y_t|x_t, \theta)p(x_t|x_{t-1}, d_{t-1}, A)p(d_t|x_t, d_{t-1}, \lambda) \quad (4.1)$$

$p(x_0)$ 、 $p(d_0)$ はそれぞれ初期状態の確率、初期継続時間の確率であり、 $p(y_t|x_t, \theta)$ は潜在変数と観測変数を関連付ける観測確率、 $p(x_t|x_{t-1}, d_{t-1}, A)$ は潜在変数の状態遷移を表現する遷移確率、 $p(d_t|x_t, d_{t-1})$ は潜在変数の継続時間を定める時間長確率である。HSMMはパラメータ ρ 、 A 、 O の事前分布をそれぞれ定義することでベイズ的な扱いが可能であり、観測値が与えられているもとでギブスサンプリング等のサンプリング手法を用いることにより、潜在変数及びパラメータの学習が可能である [16]。また、ギブスサンプリングによって得られるサンプルからモデルの周辺尤度を求める方法も提案されており [4]、モデルの事前分布、尤度、サンプリングに用いる完全事後分布から周辺尤度の近似値を効率的に求めることができる。

HSMMによる選手行動の分節化には三つの利点がある。第一に、効率的な学習アルゴリズムによって完全に教師なしの形式で、観測できない行動を観測できるデータのみから推定する事ができる。第二に、HSMMは明示的に各潜在状態の継続時間分布をモデル化するため、継続時間を幾何分布として暗黙的に仮定しているHMMに対して時間的な変化を各行動ごとに推定する事ができる。これにより、例えばステップのような急激な動作のように短い区間ですぐに完了する動作と通常時のランニングのように長時間の継続時間を持つ動作を明確に区別する事ができる。第三に、階層ディリクレ過程 (HDP; Hierarchical Dirichlet Process) 事前分布を用いることにより、各行動及び行動遷移の最適な数をデータのみから学習を通して決定する事ができる。

4.3.2 予測に基づく因果性分析

時間遅れを含む移動エントロピー (dTE; delayed Transfer Entropy) を選手の行動因果性を抽出するために用いる。移動エントロピー (TE; Transfer Entropy) は系列間の情報の流れを統計的な情報量に基づいて計る指標であり、一つの系列に対して別の系列の情報を入れることでどれだけその系列の不確実性が減るのかを表す [17]。すなわち、予測性に基づいて系列間の因果性を定義する。TEは対象系列の過去の情報で条件づけた対象系列の現在の情報と、別の系列の過去の情報の条件付き相互情報量であり、その非対称性から系列間の因果関係の方向を計ることが可能であることが利点である。しかし、フレーム間隔によって情報量が変わるため、dTEがTEの時間遅れを含む拡張として考案され [10]、以下のように定義される。

$$TE_{J \rightarrow I}(d) = \sum p(i_{t+1}, i_t, j_{t+1-d}) \log_2 \frac{p(i_{t+1}|i_t, j_{t+1-d})}{p(i_{t+1}|i_t)} \quad (4.2)$$

ここで d は注目している時間遅れであり, i_t 及び j_t が離散的な系列 I 及び J の t 時点における状態である. 選手の行動間の関係は複数の時間遅れを含むと考えられるため, 今回は一定時間の時間幅からその間の dTE のピークを取る事で因果性の値を求める. また, 図 4.4 のように複数の系列の全ての組み合わせに対して dTE を抽出することで, 因果関係の行列表現が得られる. 以降この複数の系列の因果行列を時間遅れを含む移動エントロピー行列 (dTEM; delayed Transfer Entropy Matrix) と呼ぶ.

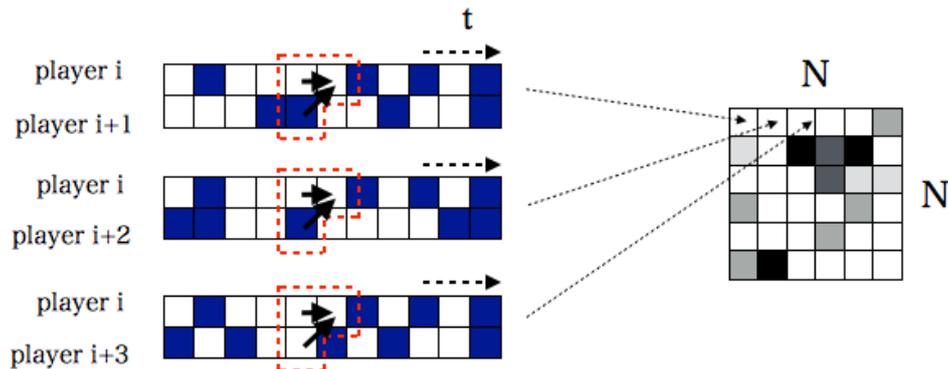


図 4.4: dTEM の構築 (図は $d=0$ 場合)

4.4 ハンドボールにおける集団行動の因果性分析

4.4.1 選手行動の行動モデルによる分節化

CVBASE06 のハンドボールのトラッキングデータに対して, 選手毎に HSMM を学習することで各系列に最適な分節化を行った. 分析に当たり, 選手の意図が方向転換や突然の加速に現れる事を仮定し, 選手行動をトラッキングデータから計算した速度 (\dot{x}, \dot{y}) , 加速度 (\ddot{x}, \ddot{y}) , 移動方向の変化量 θ の五次元によって定義した. そして分節対象となる観測データにはデータの 10 分間, 約 15,000 フレームの時系列を用いた. なお速度, 加速度は位置の差分を用いて算出し, 移動方向の変化量は前後フレーム間での速度ベクトルの内角を用いている. また, HSMM の出力分布は多変量ガウス分布を用いる事で, それぞれの分布が異なる平均を持つダイナミクスを表現するように設定する. また, 継続時間長はフレーム単位による離散時間でデータが格納されているためポアソン分布によるモデル化を行う. 潜在変数として用いられる各行動の遷移は離散的に扱うため, 遷移行列を用いてその確率を表現する. 全体のハイパーパラメータは基本的にそれぞれの分布の共役性を満たすように選択する. また, パラメータ推定のために forward-backward 方向の効率的なサンプリング法を用いるため, HDP に対して weak-limit approximation を用いた [11].

結果として各選手 (選手番号 0 から 6) の行動はそれぞれ, 8, 10, 8, 9, 7, 9, 8 (合計 59) と決定された. 分節化の妥当性を評価するため, 各系列に当てはめた HSMM の隠れ状態それぞれの持つ出力分布のパラメータ空間における位置づけを確かめる. 当然, 選手それぞ

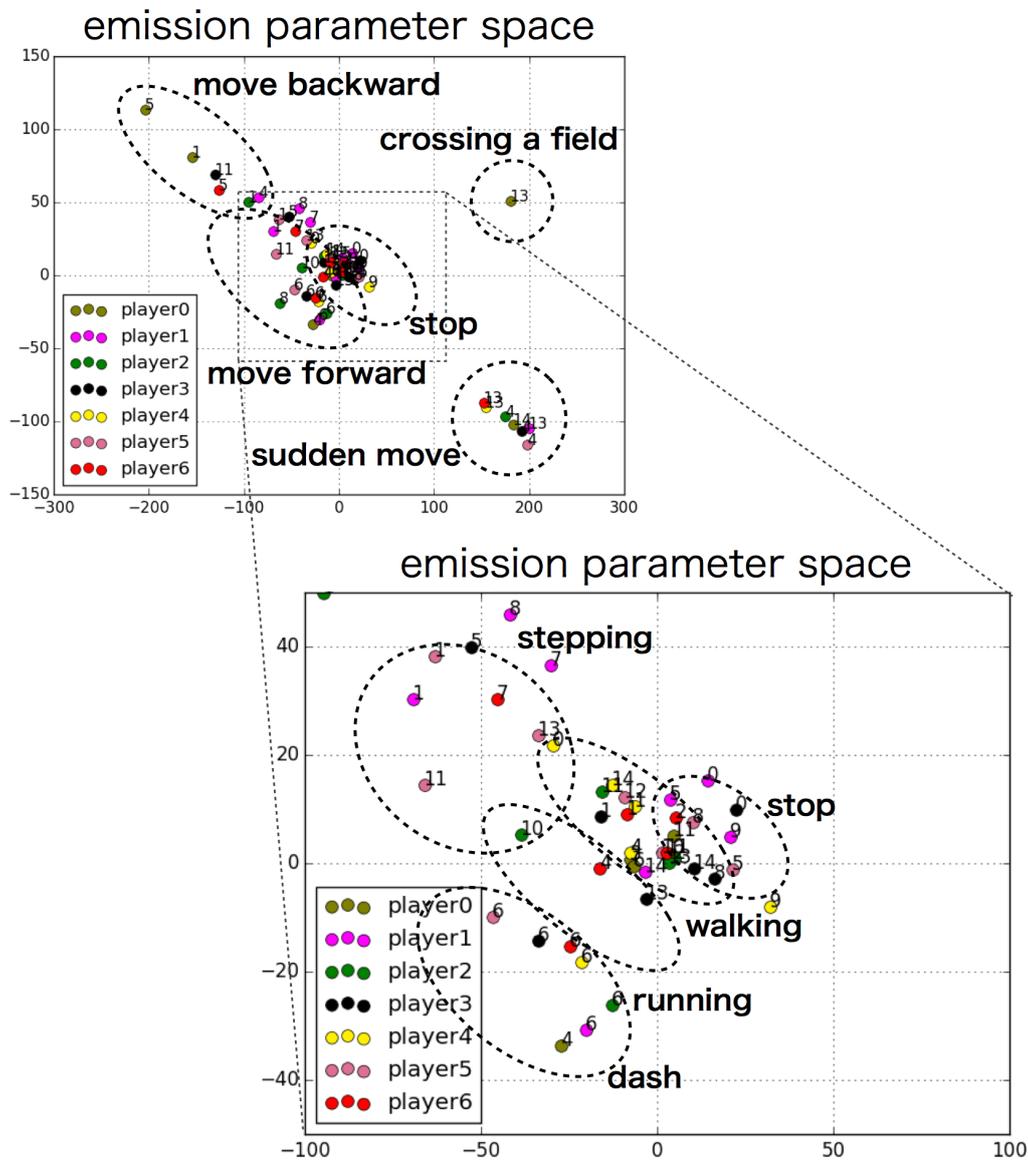


図 4.5: パラメータ空間における全選手の各出力分布 (各点の右上の文字は各選手の行動に対応する HSM 潜在状態の番号)

れらの速度や加速度の時系列は異なるが、例えば、急激な速度変化やパス回しのターン等、時系列を分節化した大まかな行動の単位は試合の中で多くの選手に共通すると考えられる。そこで、選手全ての HSM 潜在状態の出力分布間の距離行列を基に多次元尺度構成法 (MDS; Multi Dimensional Scaling) を用いて低次元パラメータに投影する。具体的には隠れ状態の多変量ガウス分布の平均と共分散パラメータの距離を、カルバック・ライブラー情報量 (Kullback-Leibler divergence) を用いて計った。なお、一般に KL 情報量は非対称であるため、可視化するにあたり二つの確率分布の両方向からの KL 情報量を平均した計

量を用いて分布間の距離行列とし、その距離行列をもとに多次元尺度構成法により二次元でパラメータ空間を表現した。

パラメータ空間における出力分布を図4.5に示す。散布図の色はそれぞれ異なる選手を表し、点の右上の文字はその選手のHSMMの隠れ状態の番号を表す。また、図4.5中の点線の楕円はパラメータ空間における大まかなグループを表す。これらグループに含まれる番号を持つ行動を各選手毎に動画データを用いて目視による確認をしたところ、静止(stop)、歩行(walking)、走行(running)、ダッシュ(dash)などと分類することができ、多くの選手が共通して行う行動とあまり行われない行動といったように、その行動に対する出力分布の集まり方に対応が見られた。このことから、選手の移動行動モデルとして利用したHSMMによる分節化が、人間の判断による分節化に近く、各選手の行動として適切に分節化していると考えられる。

4.4.2 各集団行動における行動間の因果性の分析

分節化を施し、符号化された各選手行動間の因果性を抽出するため、集団行動のアノテーション(速攻、守備の序盤等)が付与された区間を時間窓として、全選手が行動を切替えたタイミングの時系列の組み合わせに対してdTEを計算しdTEMを構成する(図4.6)。分節化された行動の切り替えは、時間的に前の行動と同一の行動の場合には0、切り替わった場合に1とするように求める。さらに、他の選手の行動が行われてから1秒間(25フレーム)の因果性を捉えるため、25フレーム分のdTEMを構成し時間的なピークを選択して1秒間中の最大値を要素とする行列を計算する。これは、選手は多くの場合で他の選手の行動や意図を基に短時間で行動を切り替える必要があるためである。そして分析時の可視性を得るためdTEMを隣接行列として選手の行動間の関係を表現する有向グラフにより表現する。

分析対象の基本的なフォーメーションを図4.7に示す。図4.7Aの攻撃時は、0番の選手がキーパー、6番が中央に位置し、1,5番の選手がそれぞれ左右サイド、2,4番の選手がそれぞれ左右サイドバック、3番の選手がセンターバックにポジションを取る。図4.7Bの守備時では、右サイドの選手に関して4番と5番の選手が入れ替わり、中央は1番と6番の選手が入れ替わる。

図4.8に各集団行動において特徴的であったdTEMの例を示す。図4.8aは攻撃の終盤の集団行動であり、一つのパスの連鎖及び一つのシュートを含む。この攻撃の集団行動は選手1のパスから始まり、選手2,3,4,5と続いていく。抽出された因果性では、選手2が右サイドの他の選手に対して強い影響を持っている事が分かる。図4.8bは攻撃の終盤の集団行動であり、この場面では相手チームが右サイドから攻め、その後左サイドへの攻めに切り替わっている。抽出された因果性は敵選手の正面にいる選手1から他の選手へ強く現れている。また、スペースを埋めるために動いた選手6及び3からも左サイド及び中央の選手への影響が見られる。

4.4.3 考察

ハンドボールは攻撃と守備の場面どちらの場合にも、フィールドプレイヤーが一斉に攻撃し守備をするという特徴がある。攻撃の場面では、敵及び敵ゴールを囲いパスを行うか

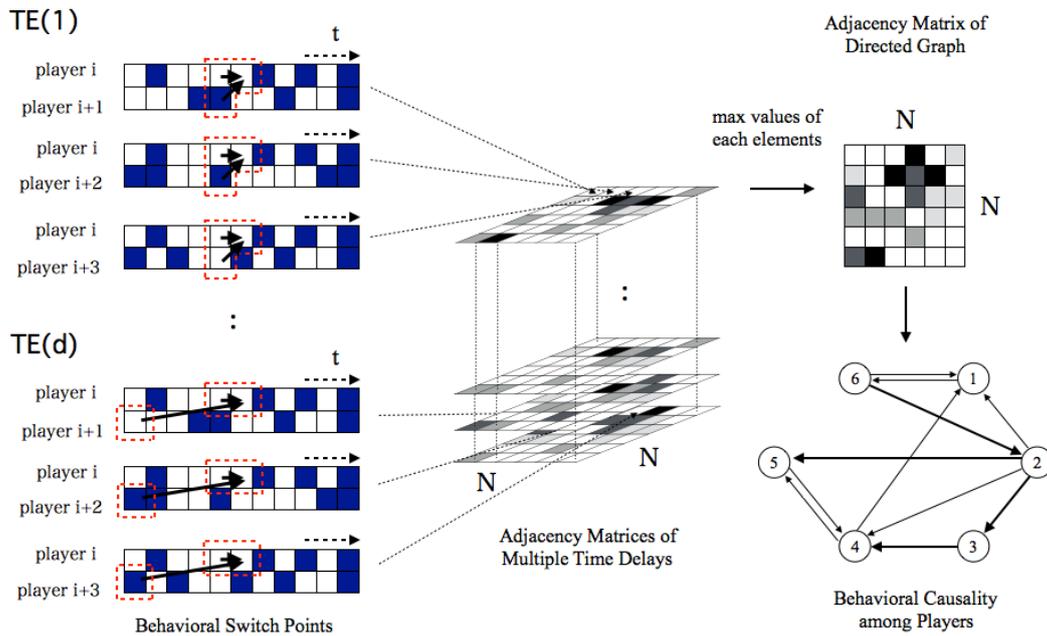


図 4.6: dTEM に基づく選手行動間因果性を表現するグラフの構成

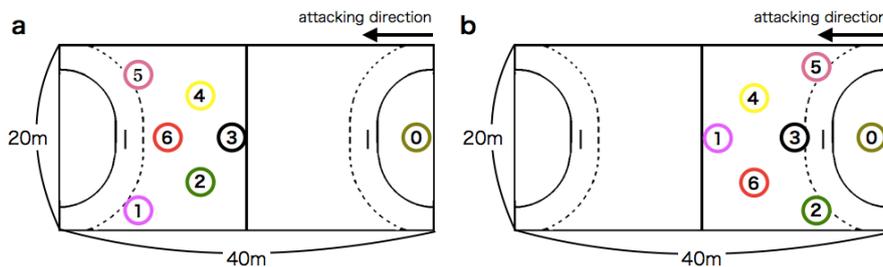


図 4.7: 分析対象のチームの基本的なフォーメーション

シュートを行う。囲まれている敵選手がゴール前に集まるため、攻撃の選手達はパスを回す事によって敵の守備を崩す必要がある。図 4.8a では左サイドから右サイドへのパスが行われており、レフトバックの選手 2 が敵が集まっている場所に向い、敵を引きつけてからパスに及んでいる。この行動からは選手 2 が守備を妨害する意図があったと見られ、そして選手 2 が攻撃の中心的役割を担っていると考えられる。他の選手は選手 2 の意図に基づき行動を切替え、その関係が有向グラフに表現されていると考えられる。また、選手 6 から他の選手への影響も見られるが、フォーメーションの中心に位置するピボットの選手として守備の妨害やチームのパスをサポートする役割が反映されている。

また守備の場面では逆に分析対象のチームは敵に囲まれ、相手チームのパスやシュートを防がなくてはならない。そのためには、選手が一丸に守備の壁を作りパスやシュートを防ぐようなスペースを埋める行動が取られる。図 4.8b では、中央の選手 1 が敵選手の正

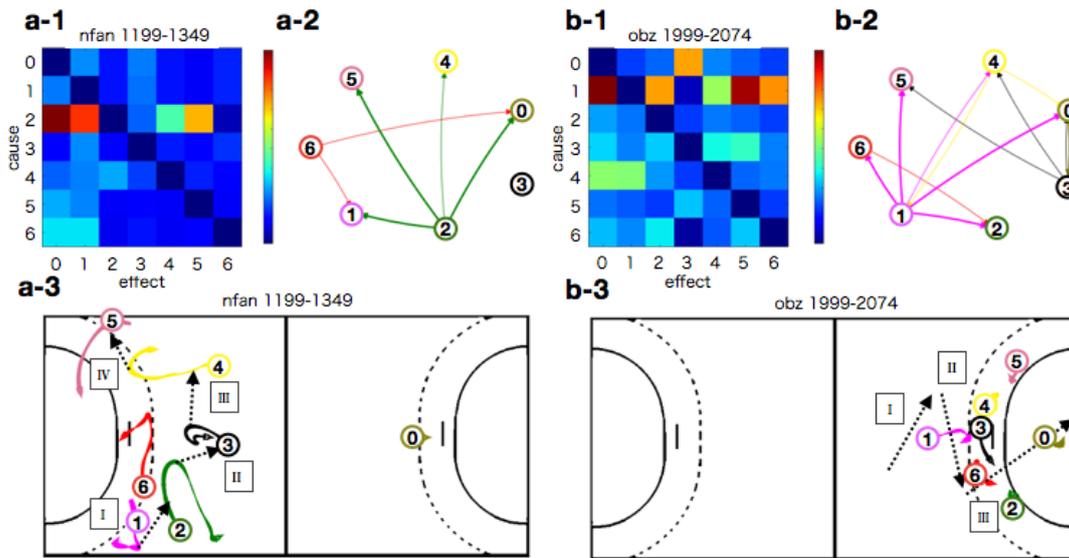


図 4.8: dTEM, dTEM を基にした有向グラフ, 選手の移動軌跡 ((a) 攻撃フェーズと (b) 守備フェーズ. グラフのエッジは因果性の大きさに応じて k-means により三段階の量子化を行い, 線の太さをそれぞれ太い, 細い, 無いとした. フィールドを表示した図の破線は先はパスの流れを示し, ローマ数字でその順序を示す.)

面に立ち攻撃を防ごうとしている. 他の選手は守備の壁を維持し, スペースを作らないために選手 1 の行動を基に行動をされると考えられる. 有向グラフは選手 1 から右サイドの選手 4, 5, 左サイドの選手 6, 2 の両サイドの選手達への因果性を明確に表現している. さらに, 選手 3 から選手 4, 5 への関係は右サイドの守備の壁を維持するための行動の繋がりを反映していると考えられ, 同様に選手 6 から選手 2 の影響がスペースを埋めるための行動の連鎖に基づく関係として抽出できていると考えられる. また, 他のアノテーションについても, 攻撃において攻めの展開において後続の選手が影響を受けて行動を繰り返す事や, 守備において前線で敵の攻撃を食い止める選手の動きに影響されて味方の守備の選手が行動を切り替える結果が得られ, 今回の分析手法によって集団における役割を反映した関係の抽出ができていると考える.

4.5 サッカーにおける集団行動の因果性分析

4.4 のハンドボールで用いた同様の手法をサッカーのデータに対して適用する. 競合を含む性質上当然敵の影響は考えるべきであり, 味方内での行動間の関係と同じように敵に対してもその影響や関係を抽出できるのかを検証する事が必要である.

ハンドボールと同様に分析には動画及びトラッキングデータを用いる. アノテーションは付与されていないため, ハンドボールと同じ基準にもとづき筆者が自ら集団行動を判断し付与した. なお, サッカーではハンドボールにはないフィールド中盤における駆け引きがあるため, フィールドをゴール方向に三分割するサード・オブ・ザ・ピッチの考えを利

用し、アタッキング・サードで行われる攻撃の終盤を nfan-attack, ミドル・サードで行われる守備の序盤を obg-middle というようにそれぞれの分割におけるアノテーションを行っている。

4.5.1 選手行動の行動モデルによる分節化

選手行動の分節化を行う。Confederations Cup2013 のスペイン対イタリアの前半10分間のトラッキングデータから得られる速度 (\dot{x}, \dot{y}) , 加速度 (\ddot{x}, \ddot{y}) , 移動方向の変化量 θ の五次元時系列を基に, 敵味方及びボールを含めた23データ毎にHSMMを学習する。なおサッカーのトラッキングデータは10fpsで記録されているため6,000フレームの時系列を用いた。ハイパーパラメータの設定は条件をできるだけ揃えるため, ハンドボールとサッカーのフレームレートに考慮して決定している。

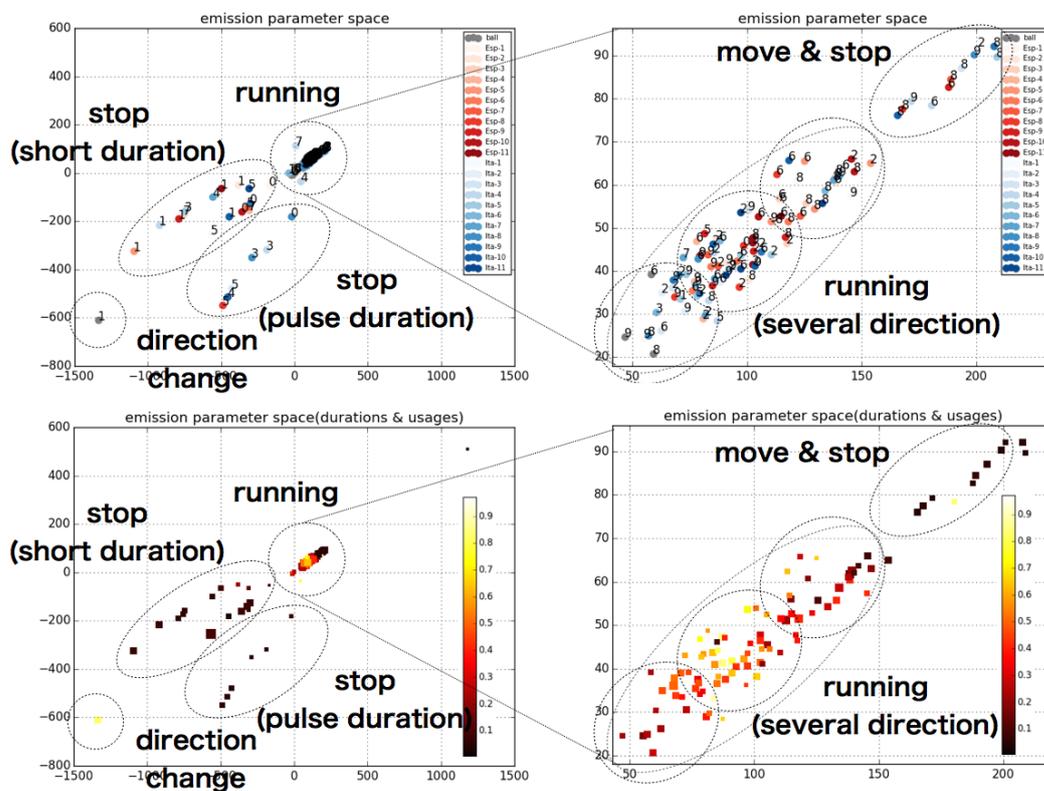


図 4.9: サッカーの場合におけるパラメータ空間中の全選手の各出力分布 (ハンドボールの場合の図 4.5 と同様に点右上の文字は HSMM 潜在状態の番号を示す。図の上下のプロットの各点の位置は同じものであるが上の図は選手毎に色分け, 下の図は行動の継続長毎に色分けをしている)

分節化の結果は, 選手全体でスペインチームで56, イタリアチームで64の120の行動, ボールの動きで10の分節を得た。また, パラメータ空間における出力分布を図 4.9 に示

す。図4.9上はハンドボールと同様に選手を色で分けたもので、今回はそれぞれのチームを赤と青に分けグラデーションで選手を分けている。またボールは灰色で表現している。図4.9下は出現頻度で点の大きさを、また明るくなるほど継続長が長く暗くなるほど継続長が短いといったように、継続長による色分けを行っている。また、動画を基にして分節化された行動と実際に行われている行動の対応を確かめた所、図4.9の破線の楕円で表示した静止(stop)、走行(running)、方向転換(direction change)のように分類できた。

それぞれの行動はチーム毎に混ざり合う形で分布しており、チームごとにそれ程片寄った行動が取られていない事が分かる。一方で、図4.9下のように継続長をプロットに重ねた場合に、速度や加速度といった行動の類似性に基づいて各行動の分布が決まっているにも関わらず図4.9の右下の走行(running)において継続時間が長い行動が中央に集まり、端に継続時間が短い行動が集まるといった行動と継続時間の関係が表れており非常に興味深い。類似したダイナミクスを持つ行動は継続時間においても似るといような事が実際に結果として現れたのではないかと考えられる。またハンドボールにおける分節化と同様に、全選手に共有される一部にしか共有されない行動の分布の集まり方に実際の行動の集まり方との対応が見られた。具体的には、図4.9左のプロット左下のボールの動きは、タイムアウト時等にフィールドの外で人に掴まれて投げられるといった動きでどの選手の行動にも当てはまらないものであるが、図4.9では選手に共有される走行等の行動から離れた場所に位置している。従って、今回も人の感覚的分節に沿った結果だと考えられる。

4.5.2 各集団行動における行動間の因果性の分析

因果性分析についてもハンドボールと同じく行動の切替えに基づいて行う。今回はハンドボールのデータとのフレームレートの違いから、時間遅れを300msから2000msまで含んで分析を行っている。

人の知覚から全身運動の開始までの時間はおよそ2秒と言われている。一方プロの選手は共有概念や状況のパターンを持っている事から予測に基づき、2秒を超えるような速度の行動の切替えが可能と考える。そのため、時間窓として広くその間の関係を捉える目的で時間遅れを決定した。

結果を図4.10に提示する。赤色のスペインチームは選手番号が大きい値ほどアタッカーを示し、青色で示したイタリアチームも同様である。またボールは0番として示している。この例では図4.10aは右サイドにパスが回る攻撃の場面だが、全体的に有効辺が得られている一方で、パスとは関係ない選手9や選手21からの影響が強く見られる。また、選手9からボールが回っている右サイドにおける選手10や選手11、そして赤の番号が小さいディフェンダーの方の選手2といった選手の行動にも影響を及ぼしている事が分かる。また、図4.10bは赤の守備の場面で、青の攻撃のつくりの場面でもある。ここでは、相手の攻撃の前線である選手14から選手15へ選手6から11といった赤の後半の番号の選手からの強い影響が見られる。

4.5.3 考察

図4.10aでは攻撃の展開において実際にボールが回っている選手間ではそれ程強い関係が見られない事や知覚されないはずの後方の選手から前方の選手への影響が見られるなど

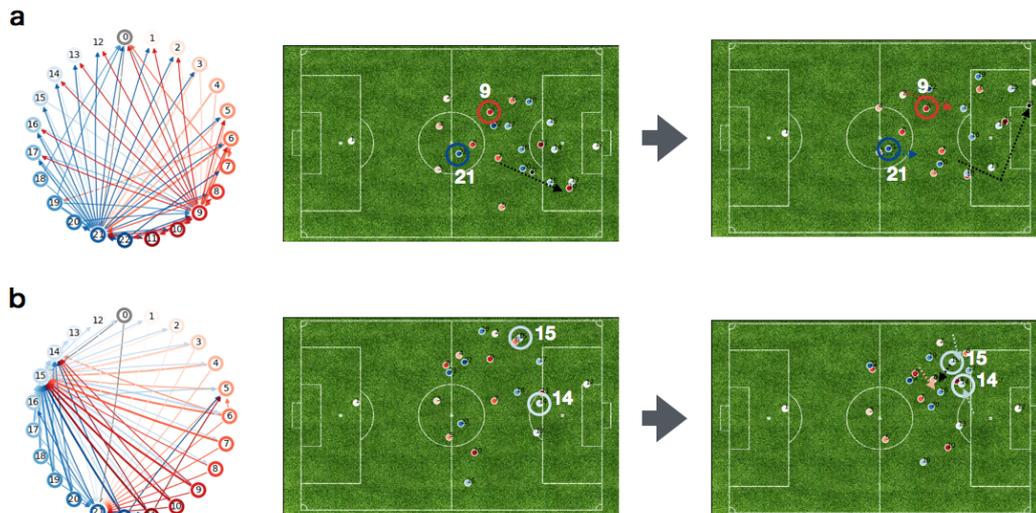


図 4.10: サッカーにおける選手行動間の因果性 (左が dTEM を基にした有向グラフ, 中央から右がその場面における変化であり, 黒の点線でボールの軌道を示す.)

未だ解釈に不明な点もあるが, 右サイドの展開の場合にも攻撃の中で左サイドに急に切り替わる事も考えると, パスとは反対の選手によるオフ・ザ・ボールの行動が因果性として抽出されたとも考えられる. 選手9からや選手10や選手11といったボールが回っている選手の行動に影響を与える事は, ボールが回る右サイドの選手も選手9の左サイドといった逆サイドの展開も考慮して行動を切替えている事が考えられる. また, 選手9は攻撃の中盤のミッドフィルダーの位置である事から, 選手2といったディフェンダーポジションの選手もこの選手の攻撃が上がっていく中心として攻撃をするために敵のゴール方向へポジションを進めていると考えられる.

図 4.10b は, 攻撃の前線の選手が守備の前線の選手への影響が出ている事から, 相手の攻撃がこちらの守備の前線に合わせて守備を避けようとしていると解釈できる. このようにサッカーにおいてもおよそハンドボールの時と同じように, 人の感覚に即した行動の分節化及び各選手の役割を反映するような集団における行動間の関係を抽出する事ができた.

4.6 まとめ

本章では, ハンドボール及びサッカーの試合における選手のトラッキングデータを利用し, HSMM を用いて各選手の速度, 加速度, 移動方向の変化量を元に行動を分節化して符号列に変換し, 出力分布のパラメータ空間での各分布の位置と動画で見られる行動の対応からその妥当性を評価した. その結果として, ハンドボール, サッカーでも同様に, 実際に多くの選手に共通する行動がモデルパラメータ空間上の行動として近い位置に分布し, 共通しない行動は別の位置に分布するといった行動の共通性が分節化された行動に反映され, 人間の感覚的な分節に近いような行動の表現が得られた. さらに, 符号列に対して dTE を用いてその因果性を評価し, dTEM を利用して分析することで, チームの連携

を特徴づける行動の因果性を考察した。結果として、攻撃や守備の集団行動における選手の役割を反映するような関係を獲得する事ができた。

今後はさらに今回の結果の妥当性を評価するために、ボールや相手チームの情報を含めてさらに多くのシーンを分析し、分節化や行動間の因果性が人間にとって自然なものが得られているのかについてゴール型スポーツの専門家を含めて評価する。また、人間の意図推定を含む協調行動を明らかにするために、選手間のアイコンタクトやハンドシグナルといった他のモダリティも含めた分析も検討していく。

第5章 仮想環境を用いた視線行動に関する協調パターン獲得実験

5.1 視線行動分析の目的及び概要

本章では、特定の共有概念を与える事による行動変化を確かめるため、視線行動を対象として仮想環境を用いた概念獲得実験を行う。特に選手の視線行動は選手の意志決定に基づいた注視点の変化を表しており、選手の意図の変化が移動よりも早く現れると考えられる。そこで、選手の視線を動画を基に獲得するためのソフトウェアを開発し、得られたデータを基にして仮想環境を構築して、ヘッドマウントディスプレイを用いた概念獲得実験を行った。

5.2 視線データ獲得用ツールの作成

選手の視線データを取得する為、三章で用いたサッカーデータにおける動画及びトラッキングデータを用いる。今回はトラッキングデータと同等のフィールドを俯瞰した二次元平面上での視線行動を用いる為、動画データとトラッキングデータを完全に同期させ、トラッキングデータの二次元作図平面上でインタラクティブにデータを生成する事を可能とするツールの作成を行った。これにより、フレームレートの異なる動画とトラッキングデータ、新たに手動で入力する視線行動データを目視により確認をしつつ入力及び編集が可能となる。図 5.1 にツールの概要を示す。

このツールは、動画とトラッキング、視線データ等を同期させ、特定のシーンの再生や確認、データの入力から編集、修正、確認といった作業を円滑に進めるために複数のモジュールから構成される。分析に用いた主なモジュールをここでは説明する。図 5.1[A][B] は視線獲得時に選手の頭部方向を確認するため動画を表示する部分となっている。図 5.1 に見られるように、対象とする選手を良く見る事ができるズームされた動画とフィールドの広い範囲を把握する為の広範囲を写した動画の両方を確認しながら分析をする目的に沿って作成している。また図 5.1[C] はトラッキングデータや獲得した視線データをフィールドを俯瞰した形で表示するプロット部分である。この図は選手を選択した後に別の場所を選択する事で対象とする選手を原点とした場合に、その後に選択された位置に対する角度をデータとして獲得でき、これにより動画を確認しながらトラッキングデータ上の視線方向を取得する事が可能となる。図 5.1[D] はデータファイルやディレクトリ、それらをまとめたプロジェクトファイルの階層を表示するが、今回はデータ獲得に用いるデータを予め規定し使う必要がなかったため実装を行っていない。図 5.1[E] はデバック用のコンソールウィンドウとなっており、データの獲得や表示場面に関する情報や間違った操作に対する警告を表示する。図 5.1[F] は動画データ及びトラッキングデータを同期させた際に主と

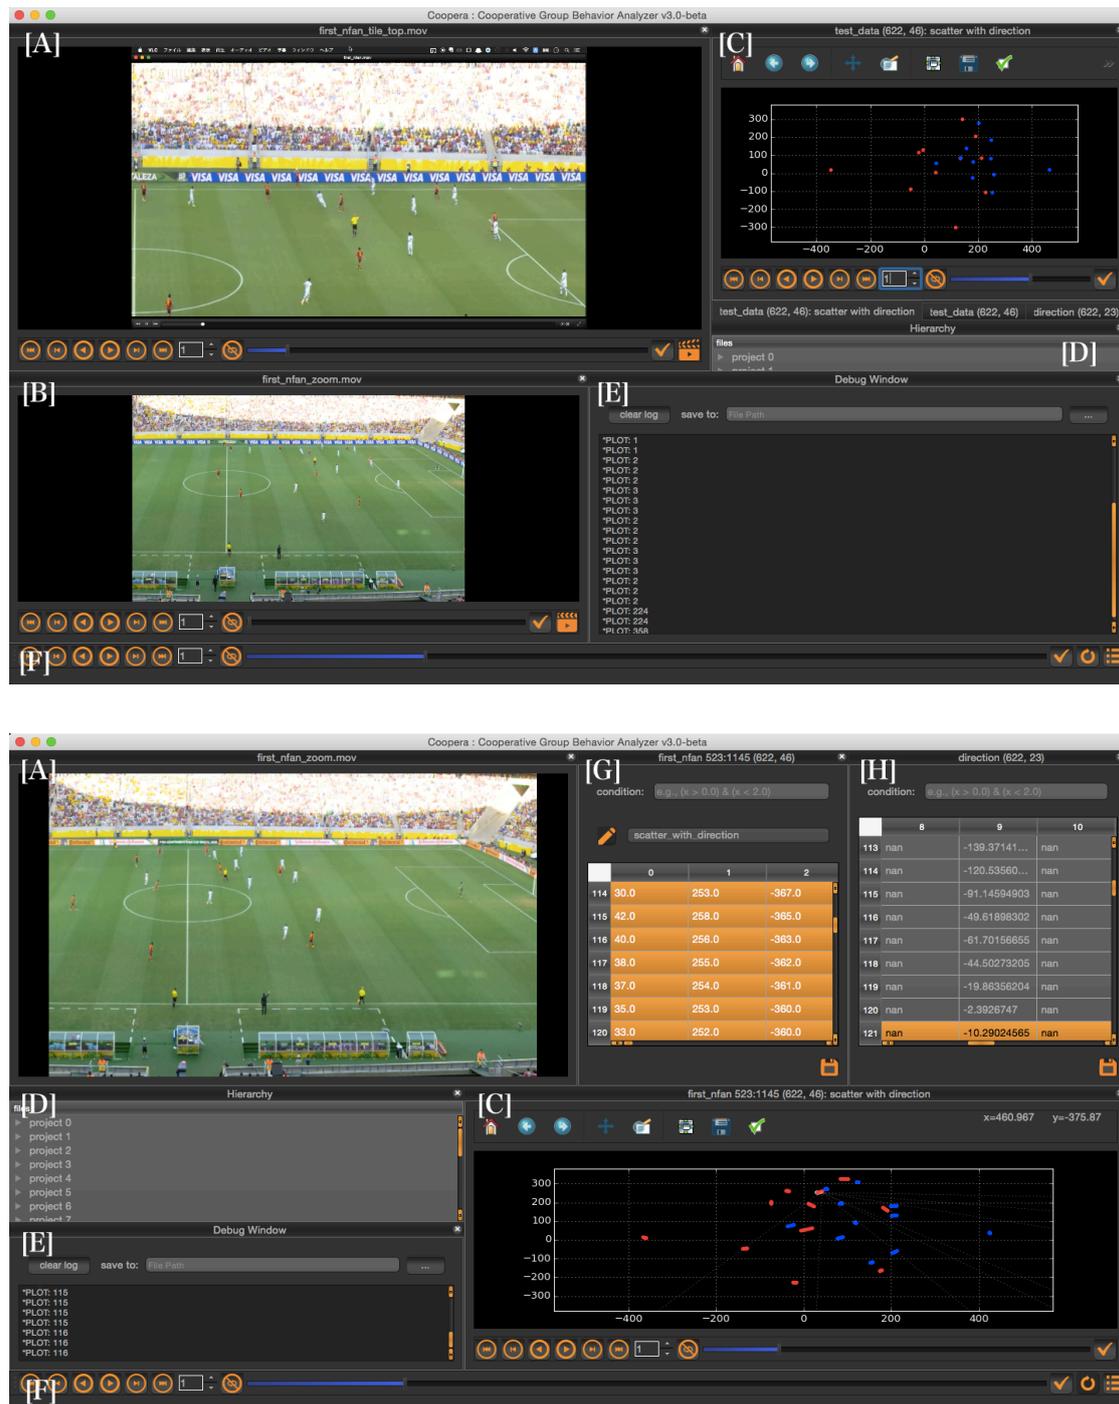


図 5.1: 分析ツールの概観の例 ([A][B] 動画, [C] トラッキングデータや視線データのプロット, [D] フォルダやプロジェクトファイル, [E] デバッグコンソール, [F] 主時間管理, [G][H] 生データの保持の役割をそれぞれのモジュールが持つ. 詳細は本文参照)

する時間を管理する部分となっており, 同期を行っている際にはこのモジュールの時間を主として動画やプロットモジュールがそれに従って時間を変化させる. 特定のイベントを

CHAPTERとして保存する事も可能であり、ここで可能な操作は、左から順に、先頭へ戻る、一つ前のCHAPTERに戻る、逆再生、再生、次のCHAPTERに移動する、最後に移動する、再生ステップ幅の変更、繰り返し、現在位置と位置の指定による移動、CHAPTERの記録、同期、同期リストの管理となっている。また、[A][B]の動画および[G][H]のプロット部分はそれぞれ独自に同様のモジュールにより時間を管理する。図5.1[G][H]はそれぞれトラッキングデータ及び視線データを表示している。ここで、生データの確認と直接の編集、さらに行を複数選択する事で図5.1[C]のプロットモジュールにおいて複数時点での情報を表示する事ができる。これにより、1フレーム毎でデータを記録する際に入力した過去のデータを同時に確認する事ができるため、過去のデータから新しく入力するデータが著しく外れる事や、目視による確認に起因する選択の揺らぎを防ぐ事に役立つ。また、図5.2[I]は同期を管理するリストであり、時間を持つモジュールが複数存在した場合にその中から主とする時間を決め、それぞれの時間の開始、終了時点を決める事で、主となる時間変化の变化分に即して他のモジュールの持つ時間を変化させる事で同期を実現する。

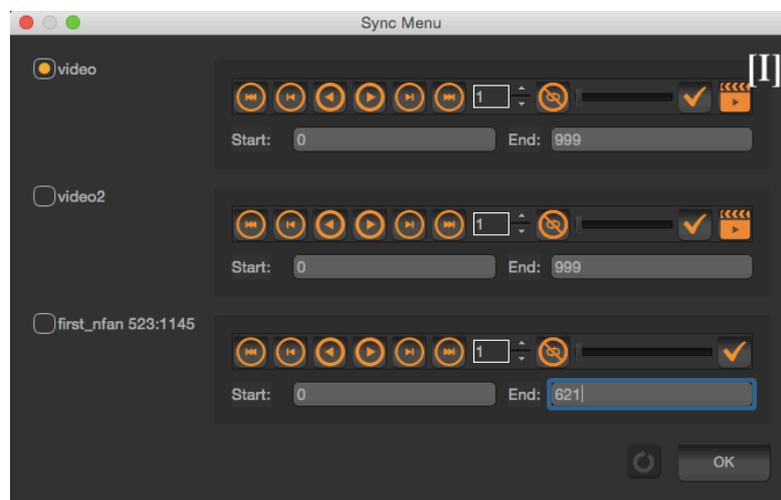


図 5.2: 同期管理リスト (図 5.1 上の二つの動画とプロットを同期させる場合)

なお、図5.1の上下のようにこれらのモジュールは必要に応じて非表示にする事や、複数表示して分析が容易な形式に自由に並べ替えられる。それにより、複数のディスプレイを用いて動画とプロットモジュールを別々のディスプレイに表示して確認する事が可能である。

5.3 HMD と仮想環境を用いた実験環境

被験者の認知過程や行動決定過程を分析するため、行動判断を行うための均一な実験環境を構築する必要がある。実際の状況に近い状態で、スポーツの場面に人に提示する事により認知訓練等が行われているが、それらは実際のフィールドでチームメンバーによってミニゲーム形式で場面を再現する形式と、ディスプレイを用いて表示する形式がある。実際のフィールドにおける場面の再現は、再現する場面に近い臨場感を持つ一方で参加する

メンバーや天気によって状況は変化してしまい再現性が低く今回の実験には適していない。また、ディスプレイを用いた形式では再現性は高い一方で、被験者の視線行動を基本として状況を切り替えるには360度に近い局面ディスプレイ等の大掛かりな装置が必要である事や敵や味方が自分の目の前にいるといった臨場感に乏しい事が問題となる。一方で近年、VR(仮想環境)の技術の進歩により操作者が頭部に装着する事によって仮想環境に入り込む事を可能とする非常に没入感の高いヘッドマウントディスプレイ等のデバイスが利用できるようになった。

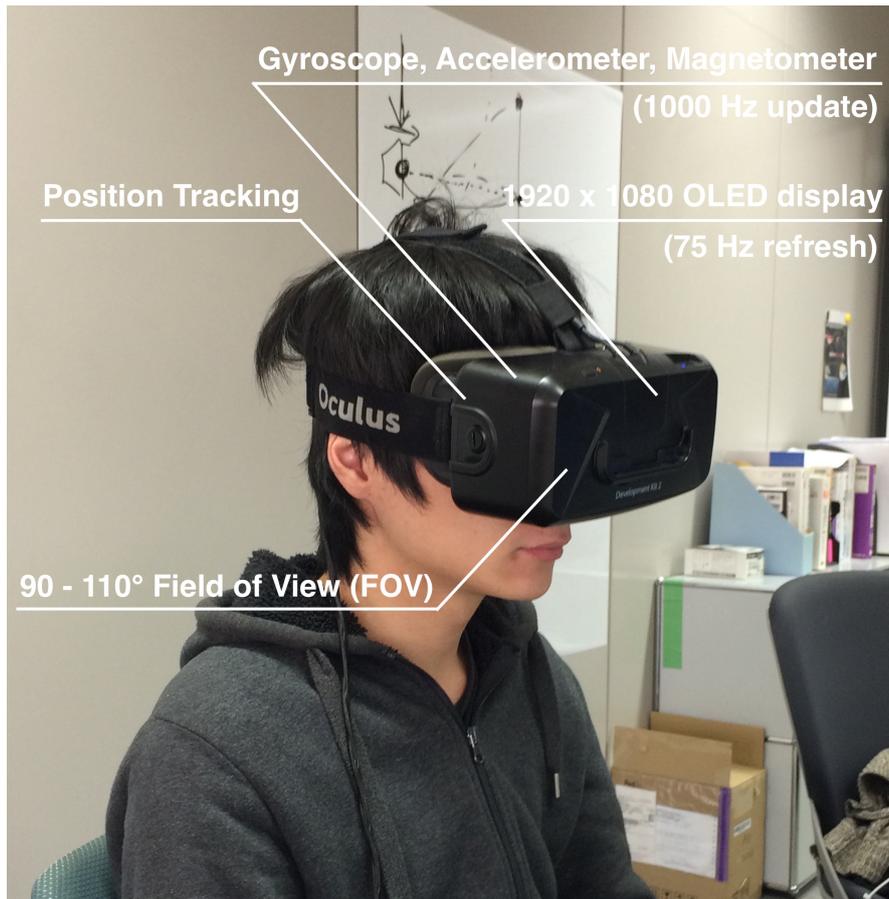


図 5.3: Oculus Rift DK2

本研究においても仮想環境を構築し、頭部に装着する事で仮想環境を利用者に表示する事が可能なヘッドマウントディスプレイ (HMD) の Oculus 社製 Oculus Rift DK2(図 5.3) を用いる。Oculus Rift は他の HMD と比較し約 110° という広い視野角と、利用者の頭を追随する事によって仮想環境を円滑に表示するヘッドトラッキングが可能である。これにより、再現性、没入感が高い形で特定の場面を再現し行動実験を行う。仮想環境については、今回 Oculus Rift を公式でサポートしている Unity Technology 社製のゲームエンジン“Unity3D”を用いて構築し実験に用いた。仮想環境において選手の役割を果たすエージェントはチーム毎に赤と白で色分けされ、それらやフィールドを含むパラメータは実際の選手や試合の規定を基に作成を行った [5](図 5.5)。

実験は頭部位置と HMD の位置を揃え、被験者がエージェントの一体となる形で行れる。これによりフィールドを見下ろすような俯瞰画像でなく、一人称視点で行動の決定を行う為、より実際の場面における判断に近い形での行動を評価する事が可能であると考えられる。また、被験者エージェントの身体を透過処理する事により自らの身体で周囲の物体が隠れてしまう事を防いでいる。仮想環境と実験の様子を図 5.4 に、また仮想環境における主なパラメータを表 5.1 に示す。

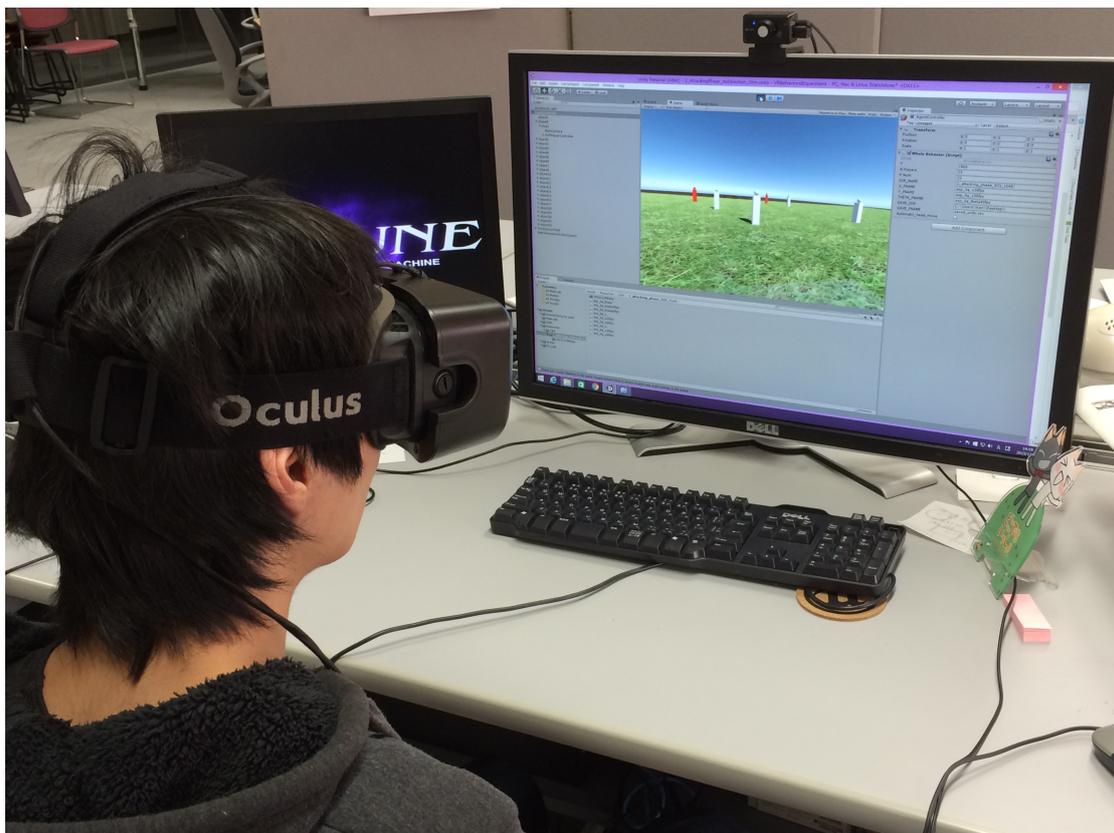


図 5.4: 実験環境 (被験者の目の前のディスプレイに表示されている画面と同じものが HMD に提示される)

表 5.1: 仮想環境の主なパラメータ設定¹

ボールの直径	2.2	フィールドの横の長さ	1050.0
選手の高さ	17.0	フィールドの縦の長さ	680.0
選手の幅	4.0	ゴールの幅	73.2
選手の頭の直径	3.0	ゴールの高さ	22.4

¹Unity3D における基本単位は 1m であるが、トラッキングデータが 10cm 単位となっていた為それに揃えて仮想環境のパラメータも基本単位を 10cm としている。

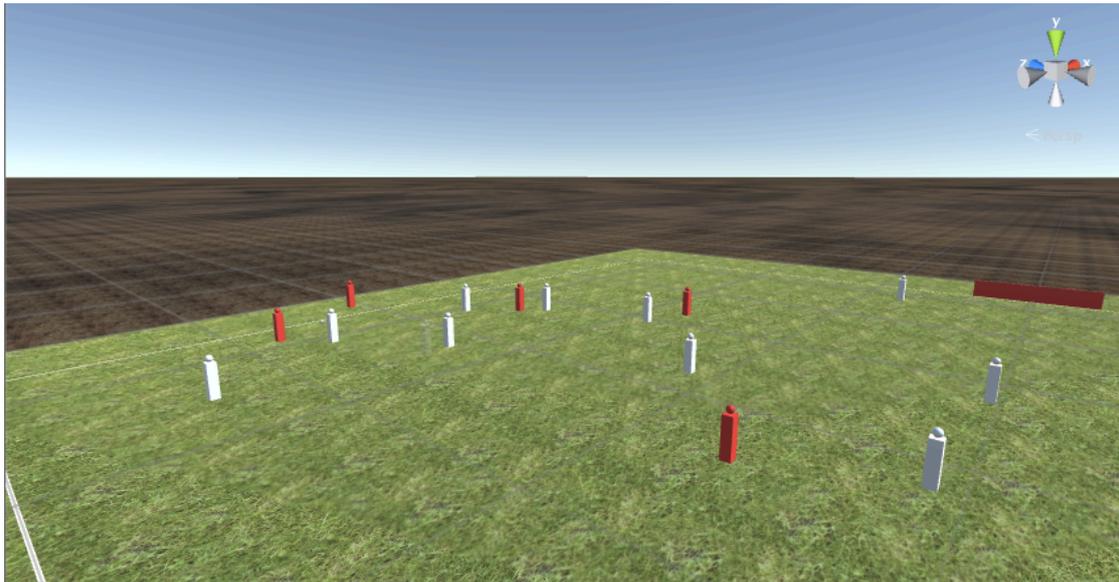


図 5.5: 実験に用いた仮想環境

仮想環境で協調場面を再現するため、10fps で選手の位置を記録したポジション・トラッキングデータ及び動画データを用いる。データには選手の視線方向は含まれていないため、動画データを元に選手の頭部方向を用いて選手の視線方向を近似した。近年の研究では人の頭部方向から視線や注意の方向を近似できる事が示唆されている [?].

5.4 視線行動に関する概念獲得実験

5.4.1 実験に用いる場面

今回実験を行うにあたって、三章で用いたサッカーのデータにおける一場面を選択し用いた。三章では攻撃の場面において味方内でパス回しを実現するための移動行動の連携が見られた事から、ボールを受けるタイミング及び送るタイミングで味方のポジションを確認する視線行動に今回は着目する。実験に用いた場面は、前半において中盤のボール確保から味方内でのパスを含みシュートに至るまでの約一分間の場面である。今回分析に用いたスペインチームはボールを保持し続ける戦術を持つ、パス回しが非常に優れているチームであり、精度の良いパスを実現するお互いの共通概念が存在すると考えられる。また、スペインチームの中心選手である Xabi Alonso 選手はインタビューの中で”We have the same idea as each other. Keep the ball, create movement around and off the ball, get in the spaces to cause danger. (選手たちは互いに同じアイデアを共有している。ボールを保持し、オフ・ザ・ボールの動きで相手にとって危険なスペースに入り込む)”と述べており [13], チーム集団における共通の行動概念を持つ事を裏付けている。

5.4.2 実験手順

今回の実験では、実際に選手が見ていた場面を直接繰り返し提示する事で被験者の視線行動の学習を行う。仮想空間におけるエージェントはトラッキングデータを基に自動で移動し、被験者は実験で指定した選手一人に対応するエージェントとして視線行動を行う。被験者はOculus Riftを頭部に装着した状態で首を振ることによって仮想環境における周囲の状況を自由に確認できる。

実験は図5.6に示すように、『事前フェーズ』、『学習フェーズ』、『事後フェーズ』の三つのフェーズに分かれている。『事前フェーズ』では被験者は頭部を動かして、対応の場面での状況を自由に確認することができる。『学習フェーズ』では被験者の視野範囲を固定し、実際の選手が行った視線行動を被験者に提示する。最後の『事後フェーズ』では、被験者は学習フェーズで選手が行っていた行動を基に頭部を動かす。被験者には、実際にその場面にいた場合にどこに注意するのかを判断するよう指示し、全てのフェーズを三試行ずつ行う。被験者は二十代の大学生及び大学院生四名で行い、実験の後に、ボールゲームの経験や視線行動を行う時にどこに着目していたかといった簡単なアンケートを行った。なお、VR酔いを防ぐため各試行の間で最長1分程度の休憩時間を取っている。

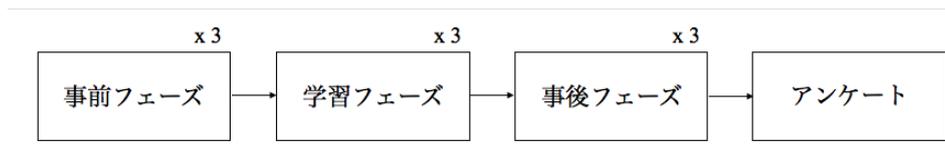


図 5.6: 実験手順

5.5 事前・事後フェーズにおける視線時系列変化

5.5.1 全体と攻撃の各段階における分散の変化

被験者のエージェントはシーンの中で4回のパスを行う。図5.7に被験者四人の事前・事後フェーズにおける視線行動の変化を角度時系列で示す。角度の時系列である為、始線をまたぐ変化が実際には小さい値であっても360°のずれを伴う大きな変化となって表れる事に注意が必要である。学習フェーズを経る事によって三試行での時系列のばらつきが減少がいずれの被験者においても見られる。

また、各三回の試行における各時点の角度分散を求めると図5.8のようになる。なお角度の分散は、一周回るとまた同じ値として戻ってくるという特殊な性質のため通常のように平均、分散を求める事ができない。そこで式5.1, 5.2のように三角関数を用いて表現する方法が用いられる。

$$(R \cos \bar{\theta}, R \sin \bar{\theta}) = \frac{1}{N} (\sum \cos \theta, \sum \sin \theta) \quad (5.1)$$

$$V = 1 - R \quad (5.2)$$

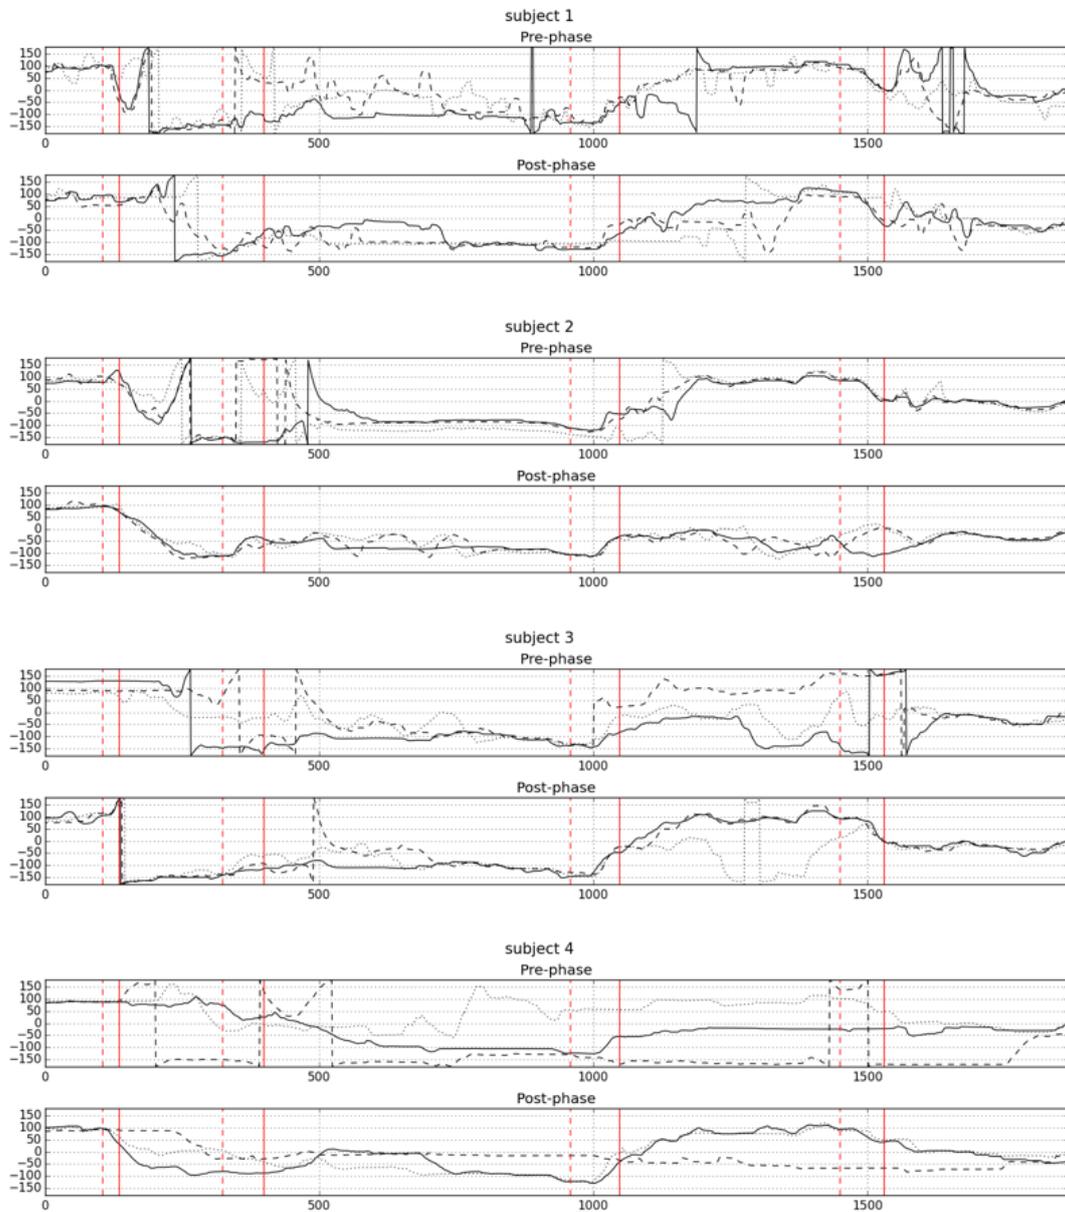


図 5.7: 事前・事後での被験者の視線行動の変化 (被験者のエージェントのボールタッチの時点を赤色点線, パスの時点を赤色実線で示す. また縦軸の角度は -180° から 180° の間を取り, フィールド上の中心から被験者のエージェントの所属するチームのゴールを結ぶ線を始線とする)

ここで、 $\bar{\theta}$ が平均、 V が分散であり、角度が揃う程動径 R が単位ベクトルに近づき、揃わない程動径 R は 0 に近づくことから、式 5.2 のように 0 から 1 の間の値として分散の大きさを表現できる。

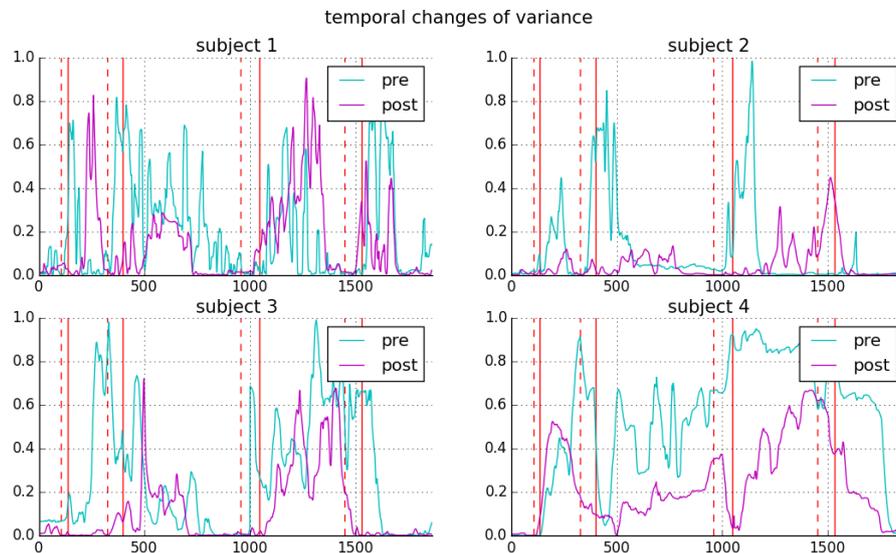


図 5.8: 事前・事後での被験者の視線行動の分散変化

図 5.8 を見ると、多少の逆転を含むものの、学習フェーズを経る事によりほとんどの被験者において明確に全体の分散が下がっている。また、被験者 1, 3, 4 における三回目と四回目のボールタッチの間の区間、被験者 1, 3 の二回目のパスの後の 300 フレーム程は、事前、事後フェーズともに分散の値が同じように高くなっている。

一方で、図 5.9 のように中盤からシュートが行われる終盤までの攻撃の場面では、敵へのしかけの段階になる程場面の移り変わりが激しくなるため、着目する場所を見失い被験者の視線行動の分散は高くなった。四回目の最後のパスの後にはただ味方のシュートを眺めているのみであるためどの被験者も分散は下がる。また、パスの直後での分散の上昇は今回の実験では実際の選手の生の時系列データに沿って勝手に自身のパスが行われるため、被験者がボールを見失った事が原因であると考えられる。これは事後アンケートにおいても、事前フェーズでは特に被験者が主に着目していたのは四人全員ともボールやボールを持っている選手であり、ボールを自分が持つタイミングでは自分の足元にボールが来る事で、下を向いてボールを確認していたとの回答があった。そのため自分の思う方向とは関係なくパスが行われることに起因するボールの探索と説明できる。

5.5.2 ボールを受ける直前の変化

協調時における視線変化を分析するために、ボール受け渡し直前の一秒間の分散の試行間平均を図 5.10 に示す。図 5.10 では、被験者 1, 3, 4 における三回目と四回目のボールタッチの間の区間、被験者 1, 3 の二回目のパスの後の 300 フレーム程は、事前、事後フェーズ

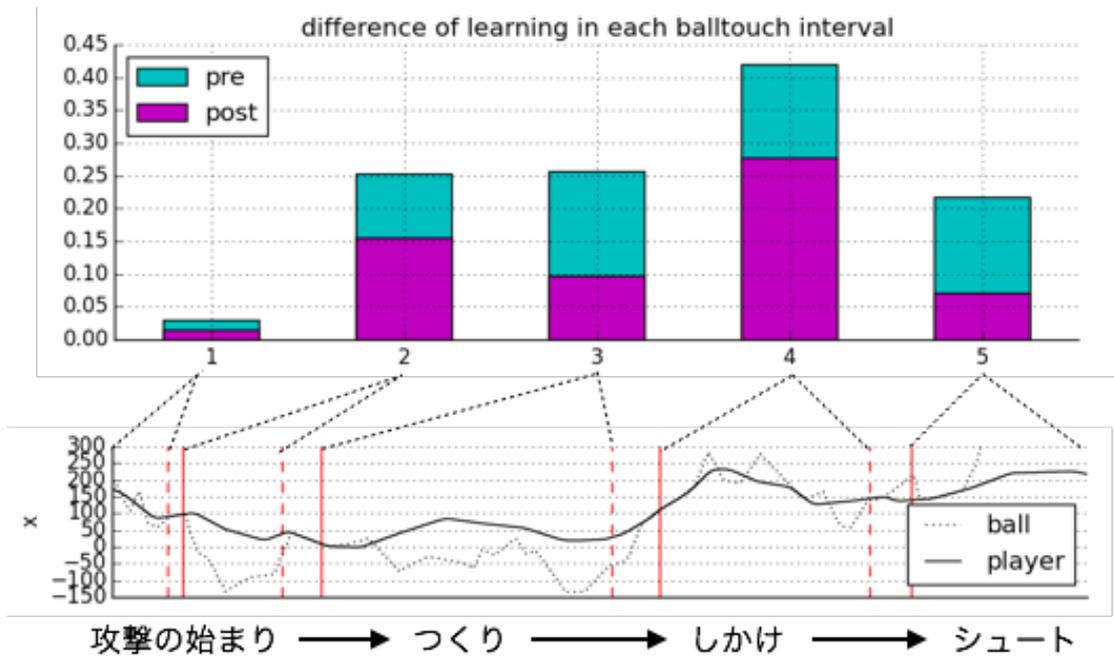


図 5.9: 攻撃の段階における分散減少の変化 (実線は選手, 破線はボールの x 軸上の位置)

ともに分散の値が同じように高くなっている箇所も見受けられるものの, 多くの場合で事後フェーズにおける分散の減少が見られる.

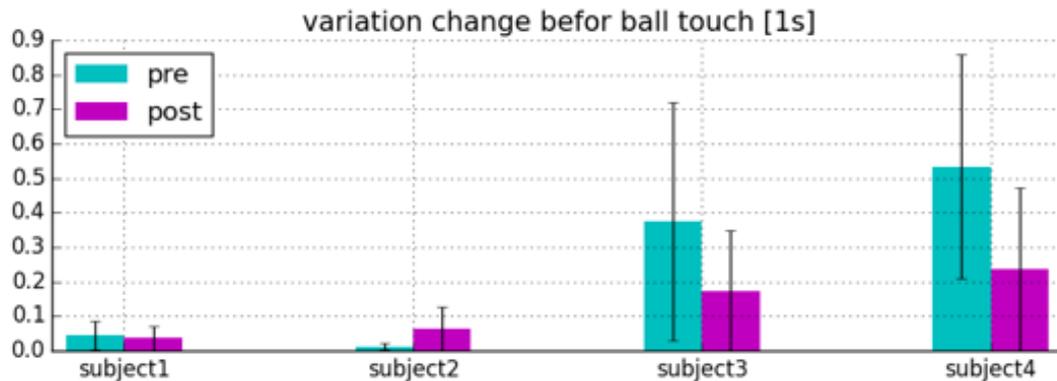


図 5.10: ボールを受ける直前 1 秒間の視線行動の分散変化

5.5.3 実際に注視していた選手の分析

さらに協調時において被験者が実際にどこに注意しているのかを明らかにするために, FOVE のアイトラッキングの機能を用いて, 被験者の視線の角度変化の差分について, 各 3 回の試行における分散をもとに被験者が実際に注視していた選手を分析する. 図 5.11 はボールを受け取った被験者が更に別の選手にパスを出す 319 - 379 frame までの値を抽出しており, このタイミングでは被験者は次に味方の FW 選手にパスを出している. 被験

者の視線からのFW選手2名の相対角度を確認すると、340 frame 前後まではFW1及びFW2に両名をほぼ同じ角度で見ているが、340 frame からそれぞれ視線を細かく移動し、350 frame 以降はFW1の選手の相対角度が0に近づき中心視で判断している傾向が見られる。このように学習フェーズを経ることで、被験者自身が協調パターンを獲得し、パス行動における能動的な探索行為を行っていると考えられる。

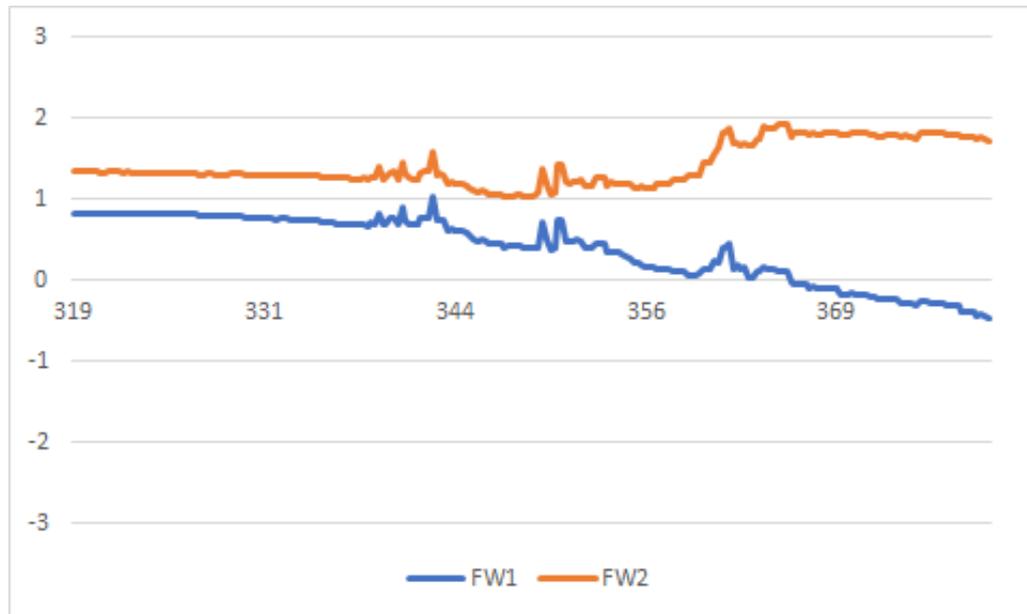


図 5.11: 被験者1の視線からの他のFW選手(1,2)の相対角度(rad)。表示した映像中で味方とのパスの受け渡しのある319-379 frameの値を示す。

5.6 考察

学習フェーズを経る事によって三試行間の時系列のばらつきの減少がいずれの被験者においても見られる事は、事前フェーズでは周囲の状況が分からず、主にボールを中心とした周囲の状況を確認する行動が多い事に対し、学習フェーズを経る事によって実際の選手が行っている視線行動を把握する事で状況の着眼点を理解した為であると考えられる。

一方で図5.9のように中盤からシュートが行われる終盤までの攻撃の場面では、敵へのしかけの段階になる程場面の移り変わりが激しくなるため、着目する場所を見失い被験者の視線行動の分散は高くなった。四回目の最後のパスの後はまだ味方のシュートを眺めているのみであるためどの被験者も分散は下がる。また、パスの直後での分散の上昇は今回の実験では実際の選手の生の時系列データに沿って勝手に自身のパスが行われるため、被験者がボールを見失った事が原因であると考えられる。これは事後アンケートにおいても、事前フェーズでは特に被験者が主に着目していたのは四人全員ともボールやボールを持っている選手であり、ボールを自分が持つタイミングでは自分の足元にボールが来る事で、下を向いてボールを確認していたとの回答があった。そのため自分の思う方向とは関係な

くパスが行われることに起因するボールの探索と説明できる。

事前・事後フェーズにおいて試行間の角度変化による分散の違いは見られないが、視線が一致するタイミングが増加し、狭い範囲で注視していると考えられる。本結果は事前フェーズでは頭部を移動して視野を大きく変化させているため、そこで注視する部位も変化し分散が大きくなるが、事後フェーズではMFの視野範囲と共通しているためそこで注視する部位が明確となり、分散が小さくなったと考えられる。これにより、特定の注視点から得られる情報が増加し、他の選手行動の分析及びその意図の推定が可能になったと考えられる。味方選手が被験者に対してパスを出し、被験者が別の選手にパスを出すタイミングにおいては、事後フェーズでは各試行での分散が大きくなった。これは、事前フェーズにおいては被験者は視覚的注意を行わず周辺視などを利用して空間全体の状況を確認しているのに対し、事後フェーズではパスを出す味方の選手を探索し、図5.11のようにその選手の行動を中心視によって確認して細かく視線を移動しているためであると考えられる。

5.7 まとめ

本章では選手の視線行動に着目し、分析ツールの構築から仮想環境を用いた概念の獲得実験まで行った。結果として、実験を通して学習フェーズを経た事後フェーズにおいて視線行動の分散が明確に減少する事が見て取れ、場面ごとにおける違いもある程度明らかになった。

しかし今回の分析の結果は協調における概念の獲得よりもボールの追従に関して迷いがなくなっただけとも解釈できてしまう。今後この問題を解決するために、ボールの扱いを被験者自身で行えるようにする、ボールタッチがない場面を選択する、といった事が考えられる。ボールの扱いを被験者自身で行うパス行動を含んだ実験を行うためには、パスの時点で場面を区切ってしまいか、他のエージェントを何らかの方法で被験者の行動に合わせて行動させる必要がある。これは三章におけるアプローチを用いて集団における関係を抽出し、そしてエージェントの行動を決定する事も考えられる。今後の課題として検討する。また、概念の獲得を確かめるために今回分析に用いた場面よりさらに多い場면을被験者に提示して、未知の場面に対して学習場面と同様に対処できるかといった実験によって獲得される共有概念の汎化性能を確かめることも重要であろう。

第6章 協調課題パターンタスクを用いた協調行動の分析とモデル構築

6.1 研究背景

我々は社会における様々な場面で他者と競合し、協力するなどの複雑な相互作用を行っており、いくつかの研究がその過程の解明やモデル化を行なっている。他者との相互作用をモデル化した研究として、Bratmanの「意図の理論」に基づく信念(B)、願望(D)、意図(I)のBDIモデル[25][20][56]、Baker, TenenbaumらによるBayesian Theory of Mind[1][2]、さらに横山らによる対人インタラクションにおけるメタ戦略の研究がある[29][28]。

BDIモデル[25][20][56]では、人は周囲の環境に関する自分の信念に基づき自分の目標を定め、その目標を達成する手段を選んでそれを実行する意図を形成し、その意図に沿って行動すると定めている。ここで他者が介入することで、我々は自分の信念と他者の意図に基づいて新たな目標を設定し、その目標を達成するための別の手段を選択して、それを実行するための新たな意図を形成する。このように人の意図は環境により自分の信念に基づいて決定される側面と、自己の内部モデルに基づいて他者の意図を推定し、その両者のバランスをとって決定するという側面があると考えられる。また他者の意図を推定する人の能力は心の理論として重要であると考えられているが、Bayesian Theory of MindとしてBaker, Tenenbaumらが提唱しているモデルでは人の意図の推定がマルコフ決定過程を基礎とした確率モデルに似た振る舞いを示すことを述べている。更に他者が複数存在する集団の場合、我々はそれぞれの意図を共有し共通の行動を形成するための「共有概念」を持つと考えられる。例えば人の優れた協調行動として実現されているサッカーでは、選手それぞれが異なる環境情報を取得した際にも、共通の目標を設定し、それを達成するための手段を瞬時に設定してそれを実現するための意図を形成することができる。このような共有概念に関与する他者の選択、さらにそこから生成される行動をモデルとして示すことが、他者との相互作用の理解に重要であると考えられる。

また横山らは社会的ロボットの構築のため、対人インタラクションにおける能動的、受動的といったメタ戦略のモデルを提案している[29][28]。相互の意図推定及び自身の意図の伝達は集団においても重要であり、さらに一対一の相互の推定だけにとどまらず集団行動においてはお互いの推定に基づき複数人で同時に共有される意図を推定する戦略が存在すると考えられる。すなわち集団における自らの役割を動的に考慮しつつ、複数の他者から協調行動に関与する他者を選択し、意図の調整を行う過程が存在すると考えられる。そこで、本研究では集団行動を抽象化した協調課題としてパターンタスクを用いた被験者行動の分析と、その結果をもとにしたエージェントシミュレーションを行う。

6.2 パターンタスク

本研究が分析に用いるパターンタスクでは同時に四人が参加をし、二次元グリッドワールドで非言語コミュニケーションのみで協調し共通の目標を達成する事を目的とする。それぞれの被験者はグリッドワールド上の円形で表現されるエージェントとして実験に参加し、各ステップにおけるお互いの行動をもとに他者の意図を推定し、目標となるパターンを形成する。目標とするパターンはエージェントの相対位置関係で表現する図形であり、4体のエージェントの内3体で構成される。そのため各被験者はパターン形成に関与するエージェントを選択して行動をする必要がある。課題は以下の五つのフェーズを各ステップごとに繰り返し、被験者が目標パターンを実現した時を一試行の完了とする。

Phase1 目標パターンを実現するために自分が選択する三点の座標を選択 (なおここで選択する座標は目標パターンを実現するための次のステップでの座標ではなく、最終的に実現したい目標パターンの座標とする)。

Phase2 目標パターンを実現するために自分が注目する人(達)を選択。

Phase3 自分の行動を上下左右静止の五つの行動の中から選択。

Phase4 Phase2で自分が注目していた人(達)が目標としたと考えられるパターンを推定し、その三点の座標を選択する。なお注目していた人が複数人の場合は、それぞれの人に対して推定する。

Phase5 Phase2で自分が注目していた人(達)が誰に着目していたかを推定しその人を選択する。なお注目していた人が複数人の場合は、それぞれの人に対して推定する。

次の試行では同じ目標パターンを用いて初期位置を変えて実施する。複数の初期位置での試行を経たのちに、目標パターンを新しく生成し再び目標パターンに対してタスクを繰り返す。

課題を実行するにあたり、次の内容をルールとして設定する。

1. 被験者は自分の座標など個人が特定できる情報を他の人に話してはいけない。
2. 目標パターンは四人の被験者のうち三人で達成すればよい。
3. 目標パターンは平衡移動した座標でも達成と認めるが、回転や反転した座標は認めない。
4. Phase2 および5で注目する人は自分を含まなくて良い。なお目標パターンを形成するために注目する人が三人以上となった場合 (例えば目標座標までの距離が全く同じ人がいた場合) は、自分が考えるよりパターン作成に関与する人三人を選択する。
5. Phase1 および Phase4 の座標を選択する時に複数のパターンが考えられる場合は、最も実現性が高いパターンを一つ選び座標を入力する。
6. Phase3 の行動選択では、移動は他の人と重なっても良いが、一マス分とし、斜め移動は不可とする。またフィールドはトラスではないためグリッドの上下左右は繋がってはいない。

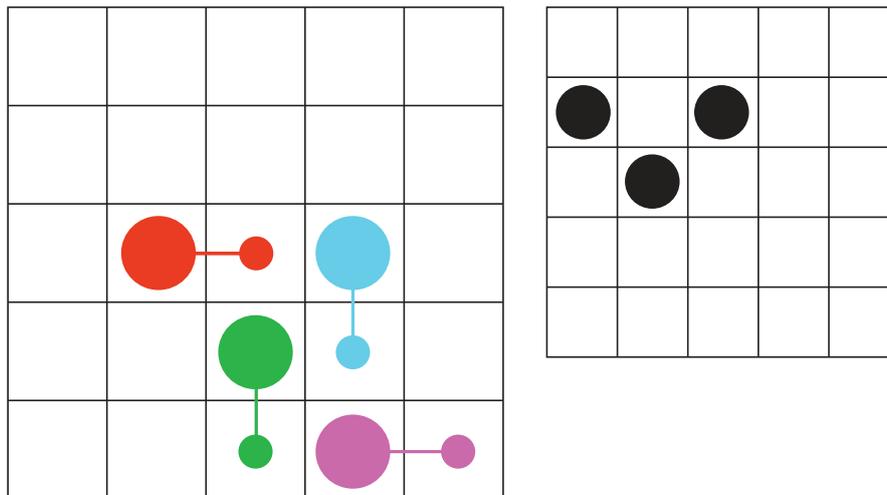


図 6.1: パターンタスク (左) 被験者が移動するグリッドワールド. 大きい円で各被験者のそれぞれの位置を示し, 小さい円によって一ステップ前に被験者がどこにいたのかを表示している. (右) 目標となるパターン. 表示されている三点の相対的な位置関係をもとに終了判定を行う.

表 6.1: 他者と目標パターンの選択

(1) Phase2		
(1-1) 必要ステップ数	0: 4, 1: 369, 2: 231, 3: 55, 4: 3	計 662
(1-2) 最適パターンとの差分	0: 571, 1: 88, 2: 3	計 662
(2) Phase5		
(2-1) 必要ステップ数	0: 9, 1: 800, 2: 471, 3: 104, 4: 12	計 1396
(2-2) 最適パターンとの差分	0: 1249, 1: 141, 2: 6	計 1396
(3) Phase1		
(3-1) Phase2 の目標パターンから最も近い 3 人が選ばれる回数	581 (86.98%)	計 668
(3-2) 上記を 2,3 人を選択した場合に限定	581 (93.71%)	計 620

6.3 人被験者による行動実験

本タスクを被験者 20 人に対し 1 から 3 種類の目標パターンで実施し, 計 77 試行実施した.

6.3.1 実験結果

実験によって基本的に次の二点の結果が得られた. 第一に, phase2 の目標パターンの選択及び phase5 での他者の目標パターンの選択において, もっとも到達ステップ数が少なくなるような最適なパターンの内の一つを選択する事が多い. また, 選択する他者に関しても基本的に到達ステップが少ない他者を選択する事が分かった. 第二に, 被験者が想定するパターンと他者のパターンとの関係について, 序盤で各被験者での新規パターンが多く考えられるものの, 全員の意図が一致をする時には一部が自身の目標パターンの変更をし, 最終的には全員一致した状態でそれぞれのパターンを継続して推定するという結果が得られた.

以下上記それぞれについて具体的に結果を見ていく.

表 6.2: 他者の目標パターンと選択したパターンの関係

(1) 全ステップ	a: 305, b: 121, c: 246	計 672
(2) 最初のステップ間	a: 59, b: 20, c: 169	計 248
(3) 最後のステップ間	a: 163, b: 74, c: 11	計 248
(4) 全被験者での Phase2 一致前後	a: 73, b: 11, c: 68	計 152

他者と目標パターンの選択に関して

まず Phase2 の目標パターンの選択に関しての推定の深さは全被験者 (3 座標入力¹, 誤ったパターンを入力していない) で表 6.1(1-1) のように 1, 2 ステップが最も多く, それ以外が少ない結果になる。また, 計算によって求められる最適なパターン (以降, 最適パターンと呼ぶ) の深さと各被験者の想定したパターンの深さの差分は表 6.1(1-2) のように基本的に 1 ステップまでのずれに取まっており, ほぼ最適なパターンの推定を行っているといえる (全体の 99.55% が 1 ステップのずれまでのパターンを推定している)。また, Phase5 における, 他者の目標パターンの選択に関しても同様の手続きで分析を行う (Phase2 と同様に 3 座標入力, 誤ったパターンを入力していないもののみを分析対象とする) と, 表 6.1(2-1) のように Phase2 と同様に全体で 1, 2 ステップで実現できるパターンを想定し, また表 6.1(2-2) のように最適パターンとの差分は基本的に 0 から 1 に収まる。このように, Phase2 と Phase5 で同様の結果が得られた。

次に, Phase1 で選択する注目する他者に関して, 被験者の選択する他者が Phase2 から計算される最も近い他者の集合に含まれるのは表 6.1(3-1) のように, 全体 668 回のうち 581 回 (86.98%) である。さらに注目他者が 2, 3 人の場合に限り集計を行うと表 6.1(3-2) のように 620 回中 581 回と, 93.71% の割合となる。

被験者の選択するパターンと他者が選択したパターンとの関係性

次に被験者が選択したパターンと他者の選択したパターンとの関係を見るため, 前後ステップでの Phase2 の選択パターンを以下の三項目に分けて分析する。

- a. 前ステップの自分が Phase2 で選択したパターンと同じパターンを選択する。
- b. 前ステップで他者が Phase2 で選択したパターンと同じパターンを選択する。
- c. a., b. とは異なる新規のパターンを選択する。

まず, 全試行全ステップ全体では表 6.2(1) のように a. の自分の想定したパターンを選択する事が全被験者の回数を累計し 305 回 (全体の 45.39%) と最も多く, 次に新しいパターンを想定する c. が 246 回 (36.61%), 他者のパターンを選択する b. が 121 回 (18.01%) という結果になった。各試行における選択の変化を確認するため 2 以上のステップの試行に

¹全ての試行及び全てのステップでの被験者のパターンの入力の座標数の内訳は {0: 3, 2: 2, 3: 668, 4: 1, 6: 2} となっており, 98%以上は 3 座標の入力を行っている。わからなかった場合の 0 や複数選択した場合の 6 以外の 2,4 点の座標入力には被験者の単純な誤入力と考えられる。

関して、最初のステップ間(ステップ1と2)、最後のステップ間(最終ステップとその前)、全員の目標パターンが一致した前後に分けてそれぞれの回数を分析する。

まず、最初のステップ間では、表6.2(2)に示すように全248回のうちc.が169回(68.15%)と最も高くなり、続いてa.が59回(23.79%)、b.が20回(8.06%)となる。一方最後のステップ間では、表6.2(3)のように順番が変わり全248回のうちa.が163回(65.73%)と最も高くなり、続いてb.が74回(29.84%)、c.が11回(4.44%)と続く。また、全員の目標パターンが一致した前後のステップに着目すると、表6.2(4)のように全152のうちa.が73回(48.03%)とc.が68回(44.74%)と同程度高くなり、b.が11回(7.24%)と最も少なくなる²。

なお全77試行中で、Phase2で選択したパターンが一致した後にパターンが不一致となる試行は一試行のみであり、それ以外の場合は全被験者のパターンが一致した場合は、その後のステップでも継続してPhase2で選択するパターンが一致する事が分かった。

6.3.2 考察

意図の誤推定を防ぐための行動の最適性

6.3.1の分析結果に見られるように、Phase2において基本的に被験者は最小のステップでパターンを実現する最適パターンとほぼ近いパターンを推定し、また最小ステップで到達する他者を注目する他者として選択する事が分かった。さらにPhase5においても同様の結果が得られている。被験者が最適パターンに近いパターンを選択する事は、課題の目標としてできるだけ少ないステップで目標を実現する必要がある事に起因していると考えられる。通常他者の意図を推定する際には、何らかの他者の行動選択の性質や特徴、癖などを用いる必要が生じるが、今回のタスクでは試行を経る事による個人の行動選択の性質や特徴の学習の影響を排し、インタラクション中の他者の行動のみからその時々意図を推定させるために、各個人のモダリティをグリッドワールド上の色の異なる円に限定、さらに毎試行毎にその色に変化する事で個人が特定できないようになっている事を被験者に伝えている。そのような状況において個人の方策を推定するの一つの策として、個人の性質によらない、行動の最適性を用いた意図の推定は有効であると考えられ、今回の結果はそのような方策が取られる事を示唆している。

実際に、全77試行中74回はパターンを最終的に実現できており、全体の所用ステップ数としてはパターンを実現した74試行上限5ステップのうち平均2.08ステップで課題を実現できている(詳細の内訳としては{1: 15, 2: 42, 3: 14, 4: 2, 5: 1}, (所用ステップ数: 試行回数))。各被験者の個人での方策が不明な状態ではこれだけ短いステップで課題を達成する事、また試行内で個人の方策を推定する事が困難である事から、お互いに最適行動をとる事によりお互いの意図の推定を容易にする事が目標パターンの推定及び注目する他者の選択の全体的な方策の一つとして共有されているのではないかと考えられる。

²全ての試行で目標パターンの一致が見られるわけではないため母数が異なる。

意図推定の負荷や食い違いを減らす集団での行動傾向の共有

また6.3.1では、2ステップ以上の試行に関して、ステップ前後のPhase2におけるパターンの選択を試行開始前後、終了前後、パターンの一致前後にわたって分析した。表6.2(2)のように最初のステップ間(第一ステップ、第二ステップ)ではc.の前のステップの自分及び他者とは異なる新規のパターンを選択する事が最も高かったが、これは初期状態では次に他者がどのように動くかわからないため、多くの場合で最初に決めたパターンと全員が動き出してからのパターンが変化する。そのためc.が多くなったと考えられる。一方最後のステップではa.の自分の前に選んだパターンと同じパターンを選択する事が最も多く、続いてb.の他者のパターンを選択する結果であったが、これは課題目標達成する時点ではそれぞれの目標とするパターンが決まっており、ここでは自分の選択したパターンもしくは他者の設定したパターンのみにはほぼ選択すべきパターンが絞られるためと考えられる。そのため、c.のように新規パターンを想定する事はこの時点では多くないと考えられる。また、Phase2での選択するパターンが全被験者で一致するステップ前後では、a., c.が高くb.が最も低くなる結果となった。これは、まずc.についてはその状況における最適パターンとして新規パターンを選んだら全員一致したような場合が当てはまると考えられ、6.3.2で考察したような状況が当てはまる。一方、a., b.に関してa.がb.より多いのは、他の全員が一致した後で、残りの一人二人が自分の意図を変更するような場面に相当すると考えられる。仮に全被験者がa.の場合はその前の時点でPhase2の一致がなくてはならないため、一致する時点では必ずb.またはc.の被験者がいる事になる。別々の意図を持つ被験者が多ければ多いほど意図の食い違いが発生し課題の達成が困難になる。b.が少ない事からほぼ全ての被験者が自分の意図を変更して同時にPhase2の一致が起こる事は考えづらい。その事から、全体的な方策として意図の変更をするべき被験者を試行内で絞り込んでいく事で、意図の誤推定とそこからくる課題達成の遅延のリスクを回避していると考えられる。

この事を示唆する一つの例として、目標達成時の移動人数があげられる。もし最後の一人や二人に自身の目標パターンを変更する人を絞りこむような方策が存在するのであれば、目標パターンを達成する時点で一人や二人を除く多くの被験者はすでに目標を達成した後に残りの被験者を待つような行動が見られると考えられる。目標パターンへの関与を否定するために離れる行動をとる被験者も含まれるため、最終の目標パターンと最短で近づく被験者の中に絞り分析を行ったところ、目標を達成した74試行中で同時に動いた人数が{0: 1, 1: 36, 2: 20, 3: 16, 4: 1}という結果となった。この結果から、残り一人二人に動くべき被験者を絞り込む事で意図の食い違いを避けるような全体的な方策が取られる事が示唆される。

6.4 エージェントシミュレーション

6.4.1 エージェントモデル

6.3章の結果をもとにエージェントモデルの構築を行い、シミュレーションを行う。シミュレーションにおいては、課題におけるPhase1から5の他者の意図する目標パターンの推定を含む行動決定過程を各ステップにおいて最短で到達できる目標パターンの集合と

初期ステップ以降に他者の行動をもとにして推定される目標パターン集合との比較を行い、多数決によって目標を絞り込む過程を実装する。

各エージェントの行動決定は Algorithm 1 に示すように、初期ステップにおいては最短となる目標パターン (Phase1), そしてそれを構成する三人のエージェントを決定する注目他者の集合 (Phase2), そしてそれぞれの目標地点に対応するエージェントの行動 (Phase3) の木構造から決定される。また Algorithm 2 のように、Phase4 と Phase5 に対応する他者の目標パターンと注目する他者は、他者エージェントの番号とその行動からこの木構造をもとに注目他者と目標パターンを逆推定する事で決定され、初期ステップ以降の行動決定はこれに基づいて推定された目標パターンと初期ステップと同様に決定した自身の目標パターン及び自身の前ステップにおける目標パターンを用いて決定される。

実験より、被験者の行動決定過程には各ステップにおける最短ステップの中でお互いの目標に早く到達するための多数決ベースの決定が取られていると考えられ、かつそれは Phase4, 5 において当人が注目する他者の意図の推定に基づく。また最短ステップで到達できる目標パターンの集合の中からパターンを選択する際には、自身を含む選択を優先的に選択する事や、自身を含む含まないに関係なくランダムに選択を行っていきその後他者の目標パターンを推定し調整していくと考えられる。そこでシミュレーションの条件を以下に設定し、次のアルゴリズムによりエージェントは行動決定する：

自己優先選択 最短経路で到達するパターンの中から、自分が含まれているパターン集合を抽出しその中からランダムに選択

ランダム選択 最短経路で到達するパターンの中から、自分が含まれているかいないかに関わらず目標パターンをランダムに選択

他者エージェント意図の推定有り 他者エージェントの1ステップ前の行動から目標とするパターンや注目している他者を推定し、それらの中から最も多く選択されているパターンを選択

他者エージェント意図の推定無し 他者エージェントの1ステップ前の行動から目標とするパターンや注目している他者を推定しない

エージェントは他者エージェントの意図の推定の有無に応じて、他者が過去に選択したと推定した目標と注目他者を現在の位置から達成できると考えられる目標と注目他者と照らし合わせ選択候補を作成する。そして、多数決目標、多数決注目他者によって候補を絞り込んだ後、自己優先かランダムかの戦略によって最終的な目標から注目他者、それに応じた目標地点と行動を決定する。

6.4.2 実験結果

エージェントシミュレーションでは初期位置と初期目標パターンを100回ずつランダムに用意し、それぞれの目標パターン到達ステップ数を「ランダム選択」と「自己優先選択」と、「他者エージェントの推定」の有無の組み合わせ条件によって比較した。初期位置で目

Algorithm 1 エージェント行動決定の基本的過程**Require:** 行動決定木, 現在の状態集合 $X_t \in \mathbb{Z}^{4 \times 2}$, 目標パターン $g^* \in \mathbb{Z}^{3 \times 2}$ **Ensure:** 行動集合 $A_t \in \mathbb{Z}^4$

現在の状態 X_t から目標パターン g^* に同じ最短距離で到達できるパターン集合を抽出し, その時刻での目標パターン集合 G_t とする

for $i = 1$ to 4 **do****if** $t > 0$ **then**

時刻 $t-1$ の自己の目標パターン g_{t-1}^i 及びエージェント i が推定した他者の目標パターン集合 $\{g_{t-1}^j(i)\}_{j=1 \dots |F_{g_{t-1}^i}|} = G_{t-1}(i)$ と目標パターン集合 G_t の共通部分を

抽出し目標候補集合 $G_c^i = \{g_{t-1}^i, \{g_{t-1}^j(i)\}\} \cap G_t$ とする

if $|G_c^i| = 0$ **then** $G_c^i \leftarrow G_t$ **end if****else** $G_c^i \leftarrow G_t$ **end if****if** ランダム選択 **then**

エージェント毎に目標パターン $g_t^n \in G_c^i (n = 1 \dots |G_c^i|)$ をランダムに選択し, g_t^i とする ... 【Phase1】

選択した目標パターンに付随する注目他者 $f_{g_t^i}^m \in F_{g_t^i} (m = 1 \dots |F_{g_t^i}|)$ をランダムに選択し $f_{g_t^i}^i$ とする ... 【Phase2】

選択した注目他者に対応するエージェント i とその行動 a_t^i を行動決定木を順方向に辿って決定 ... 【Phase3】

else if 自己優先選択 **then**

目標候補集合 G_c^i の中からエージェント i が属する注目他者 $f_{g_t^i}^m$ を持つパターン集合 $G_{c'}^i$ を決定

エージェント毎に目標パターン $g_t^l \in G_{c'}^i (l = 1 \dots |G_{c'}^i|)$ をランダムに選択し, g_t^i とする ... 【Phase1】

選択した目標パターンに付随する注目他者 $f_{g_t^i}^m \in F_{g_t^i} (m = 1 \dots |F_{g_t^i}|)$ をランダムに選択し $f_{g_t^i}^i$ とする ... 【Phase2】

選択した注目他者に対応するエージェント i とその行動 a_t^i を行動決定木を順方向に辿って決定 ... 【Phase3】

end if**end for**

Algorithm 2 他者意図の推定**Require:** 行動集合 $\mathbf{A}_t \in \mathbb{Z}^4$, 注目他者集合 $\mathbf{F}_{\mathbf{G}_t}$ 他者の目標パターン, 他者の注目他者の候補 $D[g_t^n, f_{g_t^n}^m]$ を初期化**for** $i = 1$ to 4 **do**エージェント i 及びその行動 \mathbf{a}_t^i を含む注目他者 $f_{g_t^n}^m$, 及びその注目他者集合を持つ目標パターン g_t^n を行動決定木を逆方向に辿る事で推定し他者の目標パターン及び他者の注目他者の候補として投票する**end for****for** $i = 1$ to 4 **do**エージェント i の注目他者 $\mathbf{f}_{\mathbf{g}_t}^i$ により候補をフィルタし $D^i[g_t^n, f_{g_t^n}^m]$ ($f_{g_t^n}^m = \mathbf{f}_{\mathbf{g}_t}^i$ のもの) とする**for** $j \in \mathbf{f}_{\mathbf{g}_t}^i$ **do**フィルタされた候補集合 $D^i[g_t^n, f_{g_t^n}^m]$ からエージェント j を含むものをさらにフィルタし $D_j^i[g_t^n, f_{g_t^n}^m]$ ($j \in f_{g_t^n}^m$ のもの) とするその中からもっとも票を集めた候補を, エージェント i が推定したエージェント j の目標パターン $\mathbf{g}_t^j(i)$ 及び注目他者 $\mathbf{f}_{\mathbf{g}_t}^j(i)$ とする (同票が複数ある場合はその中からランダム) ... 【Phase 4, 5】**end for****end for**

標パターンを実現してしまっていた試行を除外し, ステップ数を比較した結果を図 6.5 に示す.

結果として, 「ランダム選択」を行う場合には (1-a) の「ランダム選択」+ 「他者意図の推定無し」より (1-b) の「ランダム選択」+ 「他者意図の推定有り」の方がステップ数が少なくなり, 「自己優先選択」の場合には (1-c) の「自己優先選択」+ 「他者意図の推定無し」より (1-d) の「ランダム選択」+ 「他者意図の推定有り」の到達ステップ数が少なくなるという結果を得た. また平均だけにとどまらず, 自己優先, ランダム選択の同条件において, 他者意図の推定を行う方が他者意図の推定を行わない場合より分散が減少する結果が得られた.

6.4.3 考察

実際の被験者行動としては, 初期のステップにおいては各々位置から目標パターンへ到達するための最短ステップの可能性を計算しそれをもとに行動決定を行い, 続くステップから他者の行動をもとに目標パターンを推定し調整する過程となる事から, 今回の結果は実際の被験者が取りうる行動に近い結果となっていると考えられる. 人被験者の実験結果としても, 他者意図推定の誤推定を防ぐために最適性や多数決に基づく明確な行動戦略を持つ事が明らかになっている事から, 協調における共通目標の曖昧性を取り除くために, 他者意図に基づく多数決による目標と注目他者の絞り込みを初めとして, さらに自己優先性を取り入れる事が有効である事がこれらの結果から伺える.

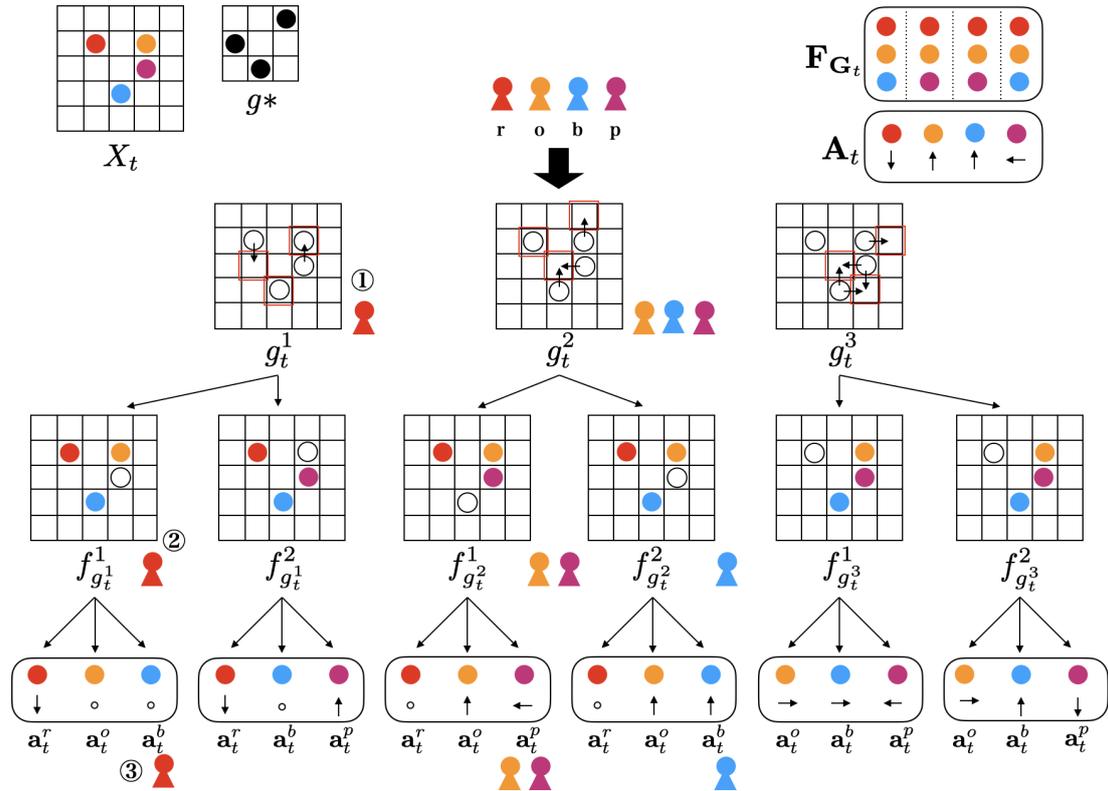


図 6.2: 順方向の行動決定過程

6.5 まとめ

本研究では協調的な集団行動における行動決定過程を明らかにするために、協調課題パターンタスクの行動実験に基づくエージェントシミュレーションを行った。シミュレーションにおいては、実際課題における Phase1 から 5 の過程をエージェントの最短目標パターンの推定と他者の目標パターンの逆推定に基づく調整として実装し、条件として「ランダム選択」、「自己優先選択」の戦略、「他者エージェント意図の推定」の有無に関する四つの組み合わせ戦略を持つエージェントモデルを作成し、目標到達ステップ数の分析を行った。シミュレーション結果より、「自己優先」及び「他者エージェント意図の推定」の両戦略を持つエージェントが最も早く目標パターンに到達することができ、人間の行動実験と同様の結果が得られた。分析の結果と合わせて、目標や注目する他者に関する多数決にさらに自己優先的な振る舞いを加える事による選択候補の絞り込みと他者から推定される際の戦略の明確化が行われているという示唆を得た。また被験者行動の中には、他者を明示的に誘導するような行動として特定の位置から想定される目標パターンの中から行動を通じて不確実性を現象させるような行動がありうる事から、今後更にエージェントモデルとしても他者視点における自己行動の不確実性の推定を含めたモデル化を行なう事で、人集団での行動における内部過程をより詳細に分析する。

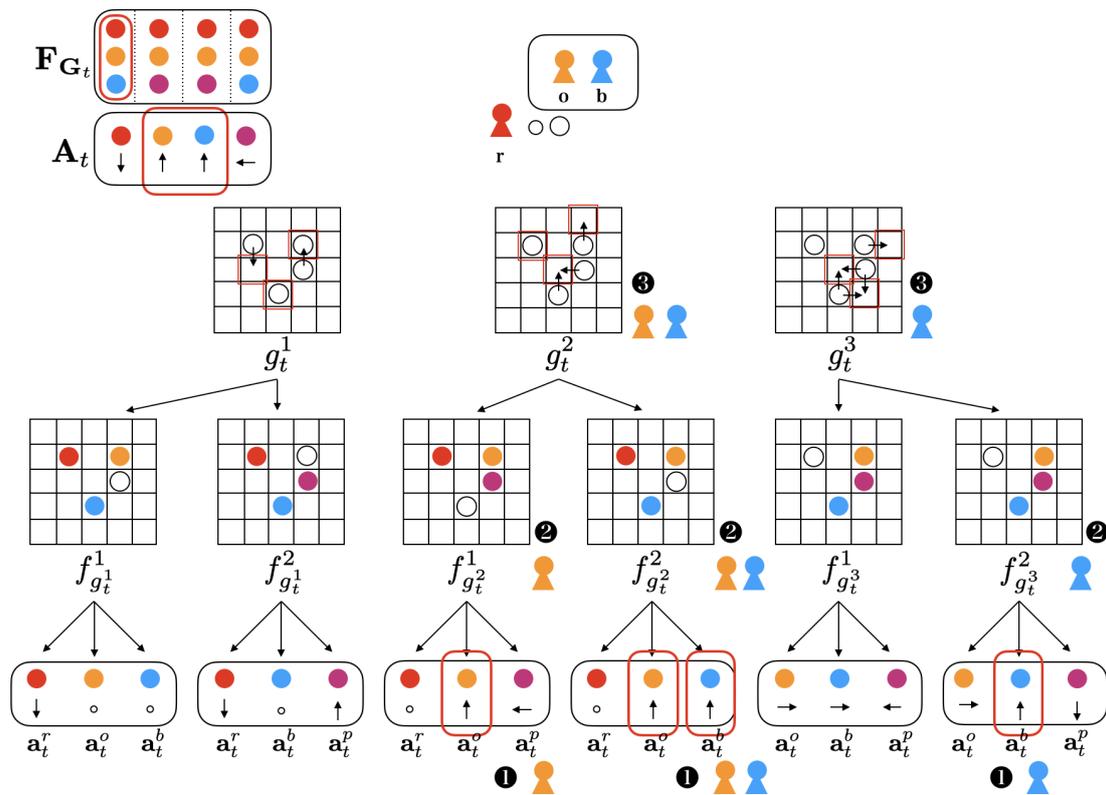


図 6.3: 逆方向の他者意図推定過程

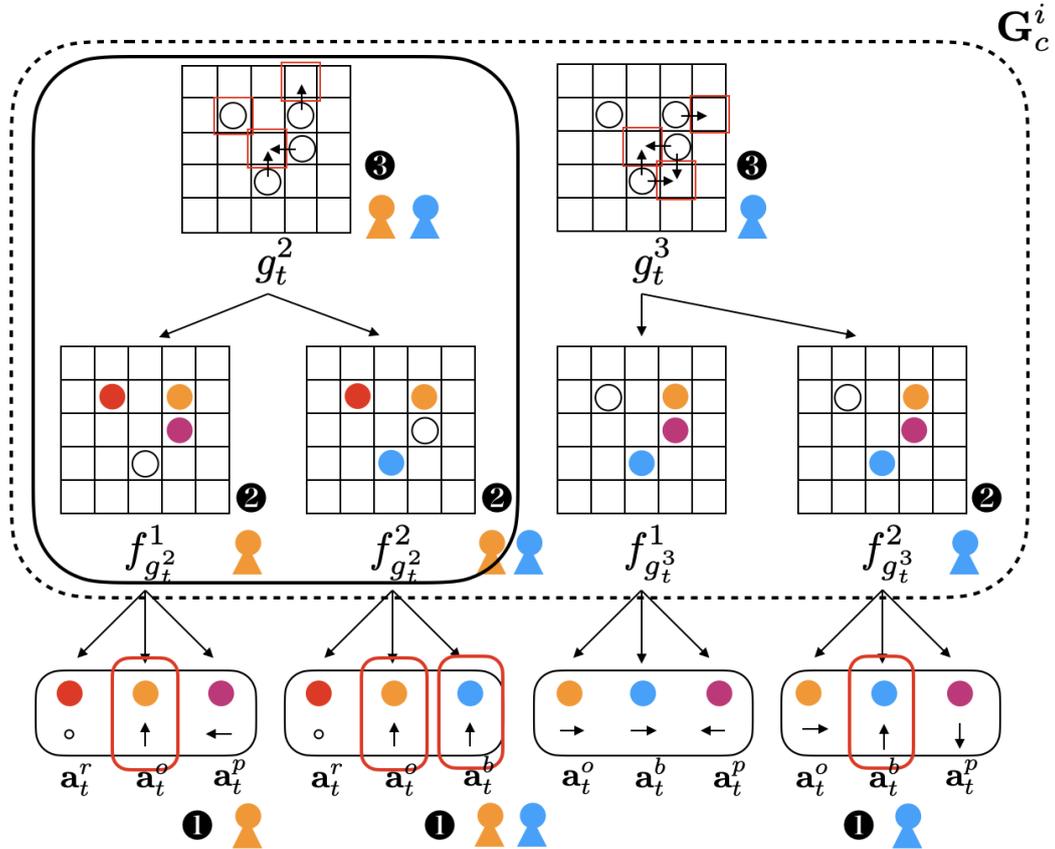


図 6.4: 他者意図推定における自己優先性

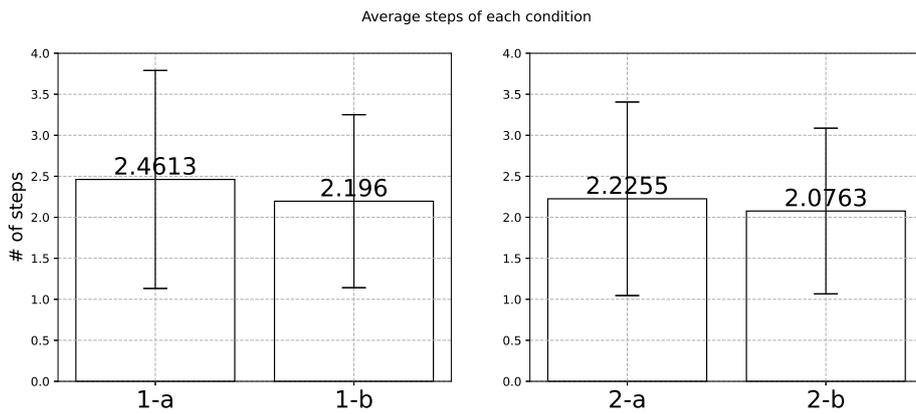


図 6.5: 目標パターン到達のステップ数の比較 (1-a) ランダム選択+他者意図の推定無し (1-b) ランダム選択+他者意図の推定有り (1-c) 自己優先選択+他者意図の推定無し (1-d) 自己優先選択+他者意図の推定有り

第7章 まとめと将来の課題

本論文では、協調的集団行動における個人の行動決定を明らかにするという目的のもと、球技における実試合データや協調課題を通じた分析的・構成論的アプローチによって研究を行った。本研究の目的について、何が明らかになり何が未だ解決すべき問題として残っているかを本章においてまとめる。

7.1 実試合データを用いたパスレシーバ選択のモデル構築

まず一つ目の研究として、集団における個人の行動決定を明らかにするために、サッカーにおけるパスレシーバ選択の分析とモデル化を行った。分析を通じて選手の視線の重要性がわかったことから、視線に基づく局所的な関係性のみでパス行動を記述するため視線重み付けフィルタとロジスティック回帰を組み合わせたモデルを構築した。その結果として実際にパスを出す時点での静的な場面においては高精度で実際のレシーバを予測する事ができた事、また動的な場面においてもモデルを繰り返し適用する事でパスが成功しやすくなる事を確認した。この結果によって、行動決定の際に視線を考慮する事によってパスレシーバ選択における相手を高い精度で予測する事が可能という事がわかった。

7.2 選手行動間の予測に基づく因果性分析

二つ目の研究として、選手行動間の関係を分節化モデルや因果性分析の手法によって抽出し、その有効性を実際の行動と比較する事で検証を行った。時系列分節化による行動モデルを構築する事で選手行動の分節化を行い、さらにそのパラメータ空間における出力分布の位置付けを動画データにより評価し人間の判断に近い適切な分節化ができている事を確認した。さらに予測に基づく因果性の抽出を行い、各集団行動における選手の役割を反映する因果性の抽出を行った。これにより行動同士の因果性を考慮する事で行動軌跡のみから各々の集団行動を表現するようなパターンを自動的に抽出する事が可能となった。

一方で、未だ行動の関係として選手が完全に知覚していないような後方の選手の影響などが捉えられている場合もあり、選手による他の選手の意図推定に関係ない偶然の前後関係を捉えてしまっている可能性も残されている。これは実試合における再現性の問題で、現実的な現象を対象する程当然なことではあるが同じ行動が起きる可能性は限りなくゼロに近づく。対策は三通り挙げられ、一つ目は「問題中の変数の粒度をコントロールする事」、二つ目は「再現性の高い環境を作る事」、そして三つ目が「問題そのものを抽象化する事」である。ただしこの三つはお互いに組み合わせる事も必要と考えられる。

一つ目の「問題中の変数の粒度をコントロールする事」に関しては、本研究の行動モデルによる行動の分節化、さらに行動間の因果性という統計量による表現を行ってきた。す

なわち、変数の組み合わせによる再現性の低さの問題に対して、得られる値に対して一定のレベルで抽象化を施す事により、同一とみられるパターンの数を増やすことである。最初から離散化されたアノテーションデータなどを用いる事により、抽象化された問題を対象として分析を行うのも一つの手ではあるが、そもそもアノテーションデータは等は人手により恣意的な解釈が含まれており、あえてより粒度の高いデータからパターンを抽出する事によって実際に人間が行っている抽象化に近づくというのが本研究の立場であった。しかし粒度が高ければ高い程良い分けでは当然あり得ず、むしろ抽象化の方策がどのような階層になって、どこを中心として考慮していくべきか分からなくなってきてしまう。この事については、様々なレベルでの分析を行いそこで得られた知見を柔軟な制約としてより上位または下位の分析に用いることが重要だと考えられる。行動間因果性のような統計量による表現は今後シミュレーションと実際の行動を比較する時等に、直接行動レベルで比較するのではなく統計量のレベルで比較する事が可能である事が利点となる。今後、解析手法を洗練させる事で具体的な集団行動の表現手段として利用される事が期待される。

二つ目の「再現性の高い環境を作る事」に関しては、本研究は仮想環境を構築する事で対策を行っている。すなわち、データにもとづきほぼ完全に同じ状況を作り出せる環境を作る事で同じ状況での行動を分析する事である。一方で、どこまで現実に近い環境にすべきかを注意深く選択する必要がある。三つ目の問題そのものの抽象化にも関わるが、本質を見失わないレベルで環境の近似を行わなければならない。現実世界に近く再現性の高い環境という点では仮想環境を用いる方法は多くの利点がある。特に、ロボット等では困難である複雑なインタラクションをシミュレーションし、それに没入する形で実験を行える点で仮想環境は多くのメリットがある。今後よりモデルを考えて実際に被験者とインタラクションをさせるにあたって、どのようなレベルが必要であるかを検証していく必要がある。

三つ目の「問題そのものを抽象化する事」は本研究は現在手をつけておらず、先行研究で得られる知見を参考にしているのみであるが、多くの場合において問題の本質的な部分のみを抽出する事で問題を単純化し、問題の全体を見回せるようにする事が重要である。また、エージェントを構築して人と同程度の行動を実現する構成論的アプローチで問題に取り組む際にも問題が複雑であればある程、エージェントによる人の行動の再現が難しくなってくる。問題の抽象化は再現性の確保と、エージェントと人間を直接比較する事ができる点で重要であり今後考えていくべき問題である。

7.3 仮想環境を用いた視線行動に関する協調パターン獲得実験

三つ目の研究として、視線行動に着目した仮想環境を利用した概念獲得実験を行い、学習フェーズを経る事で被験者の視線行動の分散が下がる事を確認した。現在は既存の時系列データに基づいてエージェントの行動を作成しているため、視線行動と移動行動が乖離してしまう問題を抱えている。さらに、自ら移動行動をする事ができないため、現在のままでは目的に基づく共有概念を獲得する事は困難だと考えられる。今回一場面と少なくともあるが、その場面における幾つかのフェーズにおける被験者行動の違いを確認する事ができたため、今後実験を行うにあたって、一連の長い場面ではなく、共有概念が使用されると考えられる短時間の区間を複数用意することも検討している。またデータを基にした

モデルベースで行動するエージェントとのインタラクションを実現する事によって、被験者とエージェントの相互作用を残しつつ共有概念から推定される集団行動に誘導する事等も今後のさらなるモデルの改善に関する発展として期待される。

7.4 協調課題パターンタスクを用いた協調行動の分析とモデル構築

四つ目の研究として、共通目標に対する協調行動の内部過程の分析のため協調課題パターンタスクを構築し行動実験における被験者行動分析及びモデル構築を通じたエージェントシミュレーションを行った。結果として、協調のパターンを想定する事で行動決定過程のモデルを構築し、目標選択の際の自己優先的な振る舞いや意図推定の有無による戦略の差異を明らかにした。今回はエージェントのみのシミュレーションのみを行ったが、さらに人とエージェントに対して同時に課題を行う事で集団内での一部の戦略を固定した場合にどのように戦略が切り替わるかなどの分析ができると考えられる。また被験者行動の中には、他者を明示的に誘導するような行動として特定の位置から想定される目標パターンの中から行動を通じて不確実性を減少させるような行動がありうる事から、今後更にエージェントモデルとしても他者視点における自己行動の不確実性の推定を含めたモデル化を行なう事で、人集団での行動における内部過程をより詳細に分析する事ができると考えられる。

第8章 結論

人間の協調的集団行動における行動決定に関して、球技における実行データと協調課題を用いた分析及びモデル構築を行った。本研究では、集団の意図の共有を行うトップダウンと、それぞれの行動に基づき状況に応じて動的にお互いの意図を推定しそれを調整するというボトムアップの過程を持つという共有概念を中心としてモデルを考え、それがどのような形で表現されるのか、またどのように利用され、獲得されるのかについてそれぞれ研究を行った。

第一の研究では、動画をもとにしたフレーム単位での定性的分析により、パスの場面を少数のパターンに分類し、また、選択されたレシーバがボールホルダーの視線方向を中心として三人以下に収まるという結果を得たため、ボールホルダーの視線方向に対して重み付けをした後に最も近い敵と味方選手をパスの判断の際の考慮対象とする視線フィルタを作成した。視線フィルタと多クラスロジスティック回帰を組み合わせたモデルで実際のパスの場面を学習することで、パスを出す瞬間の静的な場面では9割以上の高精度で実際のレシーバを予測できるという結果を得た。さらに、定性的分析によって得たパスの分類に適合するような定量的な結果を学習したモデルパラメータから逆に得られた。これにより、パスの意志決定におけるボールホルダーの視線の参照方向をもとにした少人数から実際のレシーバ選択が行われることを明らかにした。また、動的な場面におけるモデルの妥当性を評価するため、Robocup 2D Simulationの仮想環境を用いて、エージェントにモデル実装し検証を行った。その結果としてボールホルダーのモデルに基づくレシーバ決定だけでなく、周囲の味方選手がモデルに基づきボールホルダーの意志決定を推定することで自分自身がレシーバに選ばれるかという判断、また現在のボールホルダーがモデルベースで選ぶレシーバに対してモデルによる推論を行っていくことで、再帰的にゴールに達するまでのパスの連鎖を実現するような行動を実装し、動的なシミュレーション環境でもある程度までは有効に機能することを確認した。この結果は、当初の目的であった個人の行動から集団の行動が創発する例として、パス行動を一つの要素としてその再帰的なレシーバ選択によって集団行動が生成できることを検証できたと考えられる。

第二の研究では、ハンドボールのモデル試合のデータを利用し、選手のトラッキングデータから速度、加速度、移動方向の変化量を抽出し選手行動と定義した。そして潜在変数の数をデータの統計的性質に基づき自動的に決定するノンパラメトリックベイズ手法を用いた階層ディリクレ過程隠れセミマルコフモデルによって選手行動の数、その継続時間、遷移確率等をデータから学習し、推定を行った。結果として動画をもとに離散化された選手行動を確認した所、歩行、ランニング、ダッシュ、踏み込み等の突発的な行動のようなある程度のまとまりを持つ行動への分節化が行われるという結果を得た。そして、妥当性を検証するために作業仮説として、『選手毎の時系列を独立に分節化したとしても、試合の中で使われる大まかな行動は似るため、分節化した行動の多くは選手間で類似したもの

が得られる』という仮説を立て、モデルの出力分布をそのパラメータ空間に投影した。その結果、選手全員が持つ行動にはパラメータ空間においても選手全員分の行動が集まり、人間の判断による分類に近い分節化が確かめられ、その妥当性が得られた。そこで、次に選手行動間の因果性を見るために、予めコーチ一人の判断による集団行動のアノテーションを時間窓として、時間遅れを扱うことのできる delayed Transfer Entropy を用いることで、それぞれの時間遅れでの全選手の組み合わせの因果性を抽出した。結果として、集団行動毎にボールが回る前において、ボールが回っていない側の選手がボールの回っている選手の行動に因果性を受けるといような選手の役割を反映するような分析結果が得られた。結果としてボールホルダー以外の全選手の行動の関係性を、移動エントロピーによって定量的に明らかにすることができている。

第三の研究では、集団行動の例としてサッカーにおけるパスに関する協調パターン、また選手の瞬時の判断が現れると考えられる視線行動に着目し、協調パターンの学習実験を行った。具体的には実際の試合の選手のポジション・トラッキングデータをもとに協調行動を仮想環境で再現しヘッドマウントディスプレイを用いた没入性の高い実験環境を用意、協調パターンの共有があるとみられるパス行動を含む特定の場面を被験者に繰り返し提示する事によって学習前後における視線行動の変化の分析とその評価を行った。結果として、学習を経た後の事後のフェーズにおいて被験者の視線行動の分散が明確に減少することが見られ、さらに試合の攻撃場面での序盤からしかけやつくりといった場面ごとの学習の違いもある程度明らかになった。また特にボールを受ける直前に分散が小さくなった事が見られ、被験者はボールを受けるためのパスの協調パターンを獲得したと考えられる。今回の結果は今後さらに場面を増やし実際の学習システムを構築、検証する上で有用であると考えられる。

第四の研究では、協調課題を用いた実験を通じた分析から、課題の初期では被験者は新規パターンを数多く選択し、その後で被験者のうち少数が他の被験者の選択しているパターンに合わせるといった戦略の変化が見られた事、また計算的に最短到達ステップとなるような目標パターンを相互に推定する事で意図の誤推定を回避している事が考えられた。そこで、最適行動を通じて多数決戦略を基本とするエージェントモデルを構築し、シミュレーションを行う事で自己優先性や意図推定の有無に関する戦略の差異を明らかにした。

今後は今回得られた結果を基に、集団における個人の情報処理のモデルの構築を行う事で実際に共有概念が獲得される過程をより詳細に理解できるようにさらなる分析、モデル構築、シミュレーションを行っていく。人間の理解の観点からは、今回のモデルにおけるパラメータの有効性や聴覚等の他のモダリティに関しても認知科学や心理学、スポーツ科学の知見などをもとに検討していく。また発展の観点からは、競技におけるデータ分析や認知訓練への応用や、暗黙的に人の意図を推定して柔軟に協調する事が可能な社会的ロボットや協調エージェントの構築への応用が期待される。

謝辞

本論文の作成に当たり多くの方々にお世話になりました。ここに心からの感謝の意を表します。まず指導教官としてご指導頂いた慶應義塾大学環境情報学部武藤佳恭教授には、広い心で自由に研究をさせて頂き、そして暖かく見守って頂きました。先生の幅広い知識に基づくいつも鋭い視点からの確かなアドバイスが研究を進める上でも非常に参考になりました。ここに深く感謝の意を表したいと思います。また、同学部石崎俊名誉教授には、国際発表原稿の問題点等を指摘、また研究の相談にも乗って頂き感謝してます。副査の清木康教授には、プロジェクトの中で何を研究対象としてどう研究していくべきかという深い議論を頂き、常に研究として深い所を見据えた先生ならではの視点からのご助言を頂きました。また副査の中村修教授には、学位審査委員設置の際に突然のお願いにも関わらず快く副査を引き受けて頂き、研究全体の応用性に関する的確なご指摘を頂きました。そして副査を務めて頂いた武蔵野大学データサイエンス学部の渡邊紀文准教授には、研究を進める上で非常に多くのアドバイスと時間を割いて頂き、研究を進める上で親身に相談に乗って頂きました。大先輩として、ご指導頂きかつ支えて下さった事に感謝致します。

ノーベルコンピューティングプロジェクトの向井国昭教授、倉林修一専任講師にも、研究を進める上での様々な議論を頂き参考になりました。向井先生には数学的に難解でありながら非常に示唆に富んだ話を聞かさせて頂き、また倉林先生は研究として必要なものをしつかりと見据えたご指摘を頂き研究を進める上で参考になりました。また、総合政策学部古谷知之教授、環境情報学部永野智久専任講師には、分析に用いるサッカーのデータをご厚意により使わせて頂きました。

GBM研究会(集団行動モデリング研究会)の玉川大学大森隆司教授、同大学サッカー部監督山田信幸准教授にも他大学でありながら、お忙しい時間の中でもお会いする機会を設けて頂き研究の議論をして頂きました。山田先生にはサッカーのコーチをしている立場からの視点と、戦術に関する本の紹介等をして頂き参考になりました。この場を借りて感謝申し上げたいと思います。

武藤研究会における先輩として研究に関するコメントやアドバイスをして頂いた守谷元一氏、宮本賢良氏に感謝致します。また、修士課程の際に武藤研の研究を進める同期である迫田将裕氏、三宅冴氏、そしてノーベルコンピューティングプロジェクトのメンバーにも研究発表に際して有益な議論をして頂き感謝しています。さらに東京工科大学の実験に亀田・渡邊研究室の皆さんにも実験に被験者として参加して頂き感謝したいと思います。特に岩淵貴洋氏には、行動実験に必要な Oculus Rift や PC 等の実験環境を快く貸して頂き、大変助かりました。

最後に、大学院での研究生活において常に支えてくれた家族に感謝致します。日頃の大きな支えがあったからこそ研究活動を円滑に送ることができました。ここに深く感謝申し上げます。

本研究に関する発表一覧

原著論文

1. 糸田孝太, 渡邊紀文, 武藤佳恭, ”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”, 知能と情報 (日本知能情報ファジィ学会誌), vol.26, no.3, pp.678-687, 2014.
2. Kota Itoda, Norifumi Watanabe, Yoshiyasu Takefuji, “Model-based Behavioral Causality Analysis of Handball with Delayed Transfer Entropy”, *Procedia Computer Science*, vol.71, pp.85-91 (2015).
3. Kota Itoda, Norifumi Watanabe, Yoshiyasu Takefuji, “Analyzing Human Decision Making Process with Intention Estimation using Cooperative Pattern Task”, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10414 LNAI, pp.249 – 258, (2017).

国際学会発表

1. Itoda, K., Watanabe, N., Takefuji, Y. (2015). Model-based Behavioral Causality Analysis of Handball with Delayed Transfer Entropy. *BICA*. DOI:10.1016/j.procs.2015.12.210.
2. Itoda, K., Watanabe, N., Takefuji, Y. (2017). Analyzing Human Decision Making Process with Intention Estimation Using Cooperative Pattern Task. *AGI*. DOI:10.1007/978-3-319-63703-7_23

国内学会発表

1. 糸田孝太, 渡邊紀文, 武藤佳恭, ”実試合データに基づいたロジスティック回帰モデルによるサッカーパスの予測”, *The 28th Annual Conference of the Japanese Society for Artificial Intelligence*, 1M5-OS-05b-4, 2014.
2. 糸田孝太, 渡邊紀文, 古谷知之, 永野智久, 武藤佳恭, ”ゴール型ボールゲームにおける選手の連携を生み出す行動の因果性分析”, *The 29th Annual Conference of the Japanese Society for Artificial Intelligence*, 1L2-OS-15a-5, 2015.

3. 糸田孝太, 渡邊紀文, 武藤佳恭, ” ゴール型ボールゲームにおける視線行動に基づいた協調パターン獲得の実験的検討 ”, The 30th Annual Conference of the Japanese Society for Artificial Intelligence, 1M5-OS-14b-1, 2016.
4. 有村勇紀, 糸田孝太, 渡邊紀文, 大森隆司, ” 帰納論理プログラミング Aleph を用いたロボカップサッカーシミュレーション 2D の戦術パターン抽出”, 第 109 回 知識ベースシステム研究会 (SIG-KBS)(人工知能学会), 2016.
5. 渡邊紀文, 糸田孝太, ” 仮想環境を利用したゴール型ボールゲームにおける一人称視点での協調行動の獲得”, 脳と心のメカニズム第 17 回冬のワークショップ, January.11-13, 2017.
6. 糸田孝太, 渡邊紀文, 武藤佳恭, ”パターンタスクを用いた協調的な集団行動における意図調整過程の分析”, 思考と言語研究会, 2017.
7. 糸田孝太, 渡邊紀文, 武藤佳恭, ”パターンタスクを用いた他者意図推定を含む意思決定過程のモデル分析”, The 31th Annual Conference of the Japanese Society for Artificial Intelligence, 2G1-4, 2017.
8. 有村勇紀, 糸田孝太, 渡邊紀文, 大森隆司, ”実試合のパス行動分析に基づく RoboCup チームの作成及び行動の評価”, The 31th Annual Conference of the Japanese Society for Artificial Intelligence, 1O2-OS-30b-3, 2017.
9. 渡邊紀文, 糸田孝太, ”一人称視点の入力による集団行動の意図の推定と視線分析”, ファジィシステムシンポジウム講演論文集, vol.33, pp.547-552, 2017.
10. 渡邊紀文, 糸田孝太, ”集団の協調パターン形成を目的とした仮想環境での視線行動の分析”, The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 1O2-OS-30b-3, 2018.
11. 糸田孝太, 渡邊紀文, 武藤佳恭, ”パターンタスクを用いた他者意図推定を行うエージェントモデルの構築”, 第 46 回知能システムシンポジウム, 2019.
12. 渡邊紀文, 糸田孝太, ”協調パターンタスクの行動実験に基づいたシミュレーション分析”, The 33rd Annual Conference of the Japanese Society for Artificial Intelligence, 3F3-OS-14a-04, 2019.
13. 糸田孝太, 渡邊紀文, 武藤佳恭, ”パターンタスクを用いた協調戦略のモデル化”, The 34th Annual Conference of the Japanese Society for Artificial Intelligence, 4E3-OS-19b-01, 2020.

ポスター発表

1. Norifumi. Watanabe, Kota. Itoda, ”Pass Decision Modeling of Autonomous Agents by Analyzing Soccer Data ”, Mechanism of Brain and Mind the Winter Workshop, January.8-10, 2014.

2. 糸田孝太, 渡邊紀文, 古谷知之, 永野智久, 武藤佳恭, ”トラッキングデータを用いたゴール型ボールゲームにおける集団行動の因果分析”, 数学協働プログラム, March.19-20, 2015.
3. Kota Itoda, Norifumi Watanabe, Yoshiyasu Takefuji, ”Causality Analysis of Group Behavior in Goal-type Ball Game”, Machine Learning Summer School Kyoto., August.23-September.4, 2015.
4. 糸田孝太, 渡邊紀文, 武藤佳恭, ”仮想環境を利用したゴール型ボールゲームにおける協調パターン獲得の実験的検討”, 第9回脳科学若手の会, March.4-5, 2017.
5. 渡邊紀文, 糸田孝太, ”仮想環境を利用したゴール型ボールゲームにおける一人称視点での協調行動の獲得”, Mechanism of Brain and Mind the Winter Workshop, January. 11-13, 2017.

招待講演

1. N. Watanabe, K. Itoda, ”Human Behavior Understanding by Participating in RoboCup”, 慶應義塾大学環境情報学部パターン情報論, 神奈川県, Novemaber 2013.
2. 糸田孝太, ”実試合データに基づくロジスティック回帰モデルによるサッカーパスの予測”, 神奈川大学システムシミュレーション, 神奈川県, August 2015.
3. N. Watanabe, K. Itoda, Y. Hagimoto, ”Human Behavior Understanding by Participating in RoboCup”, 慶應義塾大学環境情報学部パターン情報論, 神奈川県, October 2015.
4. 糸田孝太, ”人間の協調的集団行動における概念の共有に関する研究”, 神奈川大学システムシミュレーション, 神奈川県, October 2016.
5. 糸田孝太, ”集団球技選手の意思決定と意図推定のモデル化”, 神奈川大学システムシミュレーション, 神奈川県, September 2017.
6. N. Watanabe, K. Itoda, ”Cooperative Group Behavior Analysis with VR Experiments and Real Soccer Data”, 慶應義塾大学環境情報学部パターン情報論, 神奈川県, October 2017.
7. 糸田孝太, ”サッカー選手行動の分析と抽象化したモデルによる集団の意思決定過程の分析”, 神奈川大学システムシミュレーション, 神奈川県, August 2018.
8. N. Watanabe, K. Itoda, ”Cooperative Group Behavior Analysis with VR and Real Soccer Data”, 慶應義塾大学環境情報学部パターン情報論, 神奈川県, November 2018.

受賞

1. 慶應義塾大学大学院政策・メディア研究科(修士課程) 加藤賞, 2016.

参考文献

- [1] Chris L. Baker, Rebecca Saxe, and Joshua B. Tenenbaum. Action understanding as inverse planning. *Cognition*, Vol. 113, No. 3, pp. 329 – 349, 2009. Reinforcement learning and higher cognition.
- [2] Chris L Baker and Joshua B Tenenbaum. Modeling human plan recognition using bayesian theory of mind. *Plan, activity, and intent recognition: Theory and practice*, pp. 177–204, 2014.
- [3] Scott Blunsden, Robert Fisher, and Ernesto Andrade. Recognition of coordinated multi agent activities, the individual vs the group. In *Proc. Workshop on Computer Vision Based Analysis in Sport Environments (CVBASE)*, pp. 61–70, 2006.
- [4] Siddhartha Chib. Marginal likelihood from the gibbs output. *Journal of the American Statistical Association*, Vol. 90, No. 432, pp. 1313–1321, 1995.
- [5] Fédération Internationale de Football Association, et al. *Laws of the game*. FIFA., 2015.
- [6] Kenji Doya, Kazuyuki Samejima, Ken-ichi Katagiri, and Mitsuo Kawato. Multiple model-based reinforcement learning. *Neural computation*, Vol. 14, No. 6, pp. 1347–1369, 2002.
- [7] Stevan Harnad. The symbol grounding problem. *Physica D: Nonlinear Phenomena*, Vol. 42, No. 1, pp. 335–346, 1990.
- [8] Alexandre Hervieu, Patrick Bouthemy, and Jean-Pierre Le Cadre. Trajectory-based handball video understanding. In *Proceedings of the ACM International Conference on Image and Video Retrieval*, p. 43. ACM, 2009.
- [9] Tetsunari Inamura, Iwaki Toshima, Hiroaki Tanie, and Yoshihiko Nakamura. Embodied symbol emergence based on mimesis theory. *International Journal of Robotics Research*, Vol. 23, pp. 363–377, 4 2004.
- [10] Shinya Ito, Michael E. Hansen, Randy Helland, Andrew Lumsdaine, Alan M. Litke, and John M. Beggs. Extending transfer entropy improves identification of effective connectivity in a spiking cortical network model. *PLoS ONE*, Vol. 6, No. 11, p. e27431, 11 2011.

- [11] Matthew J. Johnson and Alan S. Willsky. Bayesian nonparametric hidden semi-markov models. *Journal of Machine Learning Research*, Vol. 14, pp. 673–701, 2013.
- [12] Adam Kendon. *Conducting interaction: Patterns of behavior in focused encounters*, Vol. 7. CUP Archive, 1990.
- [13] Ian Ladyman. World cup 2010: Beat spain? it's hard enough to get the ball back, say defeated germany. <http://www.dailymail.co.uk/sport/worldcup2010/article-1293239/WORLD-CUP-2010-Beat-Spain-Its-hard-ball-say-Germany.html>, 7 2010. Accessed: 2015-01-02.
- [14] Janez Pers, Marta Bon, and Goran Vuckovic. Cvbase 06 dataset,. [online]. <http://vision.fe.uni-lj.si/cvbase06/dataset.html>.
- [15] Rolf Pfeifer, Christian Scheier, and Isabelle Illustrator-Follath. *Understanding intelligence*. MIT press, 2001.
- [16] Tobias Rydén. Em versus markov chain monte carlo for estimation of hidden markov models: A computational perspective. *Bayesian Analysis*, Vol. 3, No. 4, pp. 659–688, 2008.
- [17] Thomas Schreiber. Measuring information transfer. *Physical Review Letters*, Vol. 85, No. 2, pp. 461–464, 7 2000.
- [18] Eran Swears, Anthony Hoogs, Qiang Ji, and Kim Boyer. Complex activity recognition using granger constrained dbn (gcdbn) in sports and surveillance video. In *Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on*, pp. 788–795. IEEE, 2014.
- [19] Jun Tani and Stefano Nolfi. Learning to perceive the world as articulated: an approach for hierarchical learning in sensory-motor systems. *Neural Networks*, Vol. 12, No. 7, pp. 1131–1141, 1999.
- [20] Gerhard Weiss. *Multiagent Systems*. The MIT Press, 2013.
- [21] Daniel M Wolpert and Mitsuo Kawato. Multiple paired forward and inverse models for motor control. *Neural networks*, Vol. 11, No. 7, pp. 1317–1329, 1998.
- [22] Yuji Yamamoto and Keiko Yokoyama. Common and unique network dynamics in football games. *PloS one*, Vol. 6, No. 12, p. e29638, January 2011.
- [23] Yuichi Yamashita and Jun Tani. Emergence of functional hierarchy in a multiple timescale neural network model: a humanoid robot experiment. *PLoS computational biology*, Vol. 4, No. 11, p. e1000220, 2008.

- [24] デビット・マー. ビジョン-視覚の計算理論と脳内表現. 産業図書, 1987.
- [25] マイケル・E・ブラットマン. 意図と行為—合理性, 計画, 実践的推論. 産業図書, 1994.
- [26] 秋山英久. ロボカップサッカーシミュレーション 2D リーグ必勝ガイド. 秀和システム, 2006.
- [27] 奥田裕之, 鈴木達也. ハイブリッドシステムモデルに基づく人間の hochi 行動理解. システム/制御/情報, Vol. 7, No. 13, pp. 1-8, 2009.
- [28] 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.
- [29] 横山絢美, 大森隆司, 岡田浩之. 意図推定に基づく行動決定過程のモデル化とその評価 (一般, 機械学習によるバイオデータマイニング・生命現象の非線形性, 一般). 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. 108, No. 101, pp. 35-40, 2008.
- [30] 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.
- [31] 丸木恵祐, 本名信行. 集まりの構造——新しい日常行動論を求めて, 1980.
- [32] 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.
- [33] 高野渉. ヒューマノイドロボットの知能の設計: 身体運動の記号化から自然言語への展開 ((特集) 記号創発ロボティクス). 人工知能学会誌, Vol. 27, No. 6, pp. 587-593, 2012.
- [34] 高梨克也. インタラクションにおける偶有性と接続. インタラクションの境界と接続—サル・人・会話研究から」 昭和堂, 京都, pp. 39-68, 2010.
- [35] 高梨克也, 関根和生. サッカーにおける身体の観察可能性の調整と利用の微視的分析. 認知科学, Vol. 17, No. 1, pp. 236-240, 2010.
- [36] 高梨克也, 関根和生. サッカーにおける身体の観察可能性の調整と利用の微視的分析. 認知科学, Vol. 17, No. 1, pp. 236-240, 2010.
- [37] 山口和範. バasketボールにおけるチーム戦略評価: チームディフェンス力のリアルタイム評価の試み ((特集) スポーツの数理). オペレーションズ・リサーチ: 経営の科学, Vol. 57, No. 1, pp. 17-20, 2012.
- [38] 清水秀彦. フットボールデザイン. 脇田 玲, 奥出 直人 (編), デザイン言語 2.0-インタラクションの思考法, pp. 221-240. 慶応義塾大学出版会, 2006.

- [39] 上段達弘, 高野渉, 中村仁彦. 2a1-d05 すれ違いインタラクションを推論しながら群集をすり抜けるヒューマノイドロボット (コミュニケーション-ロボット). ロボティクス・メカトロニクス講演会講演概要集, Vol. 2011, , 2011.
- [40] 杉本徳和, 鮫島和行, 銅谷賢治, 川人光男. Mosaic モデルにより環境を抽象化する階層型強化学習. 電子情報通信学会論文誌 D, Vol. 89, No. 7, pp. 1577-1587, 2006.
- [41] 川人光男. 脳の計算理論, 第 236 巻. 産業図書, 1996.
- [42] 川人光男. 脳の情報を読み解く: BMI が開く未来. 朝日新聞出版, 2010.
- [43] 川人光男, 銅谷賢治, 春野雅彦. ヒト知性の計算神経科学. 映像情報メディア学会技術報告, Vol. 24, No. 38, pp. 57-64, 2000.
- [44] 川嶋宏彰, 松山隆司. ハイブリッドダイナミカルシステムによる動的事象のモデル化と認識. システム/制御/情報, Vol. 54, No. 1, pp. 28-33, 2010.
- [45] 大森隆司. ヒトの心のプロセスの計算論的理解に向けて. 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. 109, No. 461, pp. 315-320, 2010.
- [46] 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.
- [47] 大塚和弘, 竹前嘉修, 大和淳司, 村瀬洋. 複数人物の対面会話を対象としたマルコフ切替えモデルに基づく会話構造の確率的推論 (ヒューマンインタフェース基礎). 情報処理学会論文誌, Vol. 47, No. 7, pp. 2317-2334, 2006.
- [48] 瀧剛志, 長谷川純一. チームスポーツにおける集団行動解析のための特徴量とその応用 (動画像処理論文特集). 電子情報通信学会論文誌. D-II, 情報・システム, II-情報処理, Vol. 81, No. 8, pp. 1802-1811, 1998.
- [49] 谷口忠大. コミュニケーションするロボットは創れるか: 記号創発システムへの構成的アプローチ. NTT 出版, 2010.
- [50] 谷口忠大. 二重分節構造に基づく教師なし学習と記号創発: 時系列情報の分節化による記号創発ロボティクスへのアプローチ (< 特集 > 記号創発ロボティクス). 人工知能学会誌, Vol. 27, No. 6, pp. 569-579, 2012.
- [51] 谷口忠大, 岩橋直人. 複数予測モデル遷移の n-gram 統計に基づく非分節運動系列からの模倣学習手法. 日本知能情報ファジィ学会 ファジィ システム シンポジウム 講演論文集, Vol. 25, No. 0, pp. 225-225, 2009.
- [52] 谷口忠大, 榎木哲夫. 双シエマモデル 自律エージェントの為の自己組織化機械学習手法の提案. 人工知能学会論文誌, Vol. 19, pp. 493-501, 2004.
- [53] 長坂翔吾, 谷口忠大, 坂東誉司, 竹中一仁, 人見謙太郎. ノンパラメトリックベイズ二重分節解析器によるドライバ意図変化点の予測手法. 人工知能学会全国大会論文集, Vol. 27, pp. 1-4, 2013.

- [54] 鳥越規央. プロ野球の数理科学 (〈特集〉スポーツの数理). オペレーションズ・リサーチ : 経営の科学, Vol. 57, No. 1, pp. 11–16, 2012.
- [55] 伝康晴, 荒木雅弘, 岡本雅史, 高田司郎, 高梨克也, 矢野博之. 対話研究に「意図」は必要か. 人工知能学会誌, Vol. 20, No. 4, 2005.
- [56] 東条敏. 言語・知識・信念の論理. オーム社, 2006.
- [57] 鳩山由紀夫. 野球の OR (〈特集〉スポーツの OR). オペレーションズ・リサーチ : 経営の科学, Vol. 24, No. 4, pp. 203–212, 1979.
- [58] 坊農真弓, 高梨克也. 多人数インタラクションの分析手法. オーム社, 2009.
- [59] 野田五十樹. Hmm による協調動作の模倣学習. 人工知能学会全国大会論文集, Vol. 17, No. 0, pp. 207–207, 2003.
- [60] 野田五十樹. チームプレイにおける意図の利用 (〈特集〉意図研究のスペクトル). 人工知能学会誌, Vol. 20, No. 4, pp. 449–455, 2005.
- [61] 鈴木達也, 稲垣伸吉, 奥田裕之. 確率的切換えを伴う動的モデルとその行動科学への応用: データとモデルに基づいた「人を知る技術」の創出に向けて (特集離散事象システム理論によるモデリングと制御の新展開). 計測と制御, Vol. 52, No. 12, pp. 1102–1109, 2013.

付録 A

以下に参考として実試合の分析表を掲載する。

Scene	Team	Frame	Time	Player	Action
1	川崎 F	8214	0:04:34.040	C(右から 2 列目下部)	パスを待ち手で合図
1	川崎 F	8214	0:04:34.040	B(右から 3 列目下部)	周囲を見て C を確認
1	川崎 F	8221	0:04:34.270	A(右から 5 列目下部)	敵選手のパスミスを受け取り B へパス
1	川崎 F	8224	0:04:34.370	敵(右から 4 列目下部)	A のパスを見て攻撃から守備に移り 方向転換
1	川崎 F	8228	0:04:34.500	C(右から 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	川崎 F	8247	0:04:35.140	B(右から 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
1	川崎 F	8287	0:04:36.470	D(右から 1 列目下部)	C が受け取ったのを確認し、ボールを 受け取 る為に前方へ走り込む
1	川崎 F	8303	0:04:37.010	敵 1(ゴールから左に 1 列目中央)	D を確認、コースをつぶす為に前進
1	川崎 F	8322	0:04:37.640	D(ゴールから右に 3 列目中央)	C を確認
1	川崎 F	8319	0:04:37.540	C(ゴールから右に 1 列目下部)	D へのコースが無理だと判断、C が B ともコンタクトをとる
1	川崎 F	8336	0:04:38.110	C(ゴールから右に 1 列目下部)	前方向からくる DF をかわす
1	川崎 F	8402	0:04:40.310	B(ゴールから右に 3 列目下部)	C からボールを受けるためにフリー スペースへ走り込む
1	川崎 F	8417	0:04:40.810	C(左から 3 列目下部)	走っている B の動きを予測
1	川崎 F	8422	0:04:40.980	C(左から 4 列目下部)	進行方向への DF のプレスの強まり から B へのパスをしボール逃がす
1	川崎 F	8422	0:04:40.980	D(左から 5 列目下部)	B のコースを確保するために敵を引きつ ける (B のゴールへのコースがフリーに)
1	川崎 F	8457	0:04:42.140	B(左から 4 列目中央)	ボールを受け取った B はそのまま 走ってシュート (ただし失敗)

2	C 大阪	17021	0:09:27.900	A(右から 3 列目中央)	敵が別の敵からスローインを受けてキックしたボールをヘディングで前方に流す
2	C 大阪	17027	0:09:28.100	A(右から 3 列目中央)	さらに攻めていくために前方へ自分自身も走っていく
2	C 大阪	17038	0:09:28.460	敵 1(左から 1 列目下部)	A のヘディングによって移動するボールを追って守備に回る
2	C 大阪	17045	0:09:28.700	C(右から 3 列目下部)	(A とほぼ同じラインにいた選手) ほぼ同時に前方に走り出す
2	C 大阪	17063	0:09:29.300	D(左から 1 列目下部)	B(2 列目) のボール確保を予測して、自分がパスを受けるために走りこむ
2	C 大阪	17067	0:09:29.430	B(左から 3 列目中央)	右手を上げて D とコンタクトをとる
2	C 大阪	17074	0:09:29.660	敵 1(左から 3 列目下部)	この合図によって B(3 列目中央) から D(1 列目下部) へのパスコースを警戒
2	C 大阪	17077	0:09:29.760	B(左から 3 列目中央)	A が前に出したボールをサイドから出てきて確保
2	C 大阪	17077	0:09:29.760	敵 2(左から 3 列目下部)	ボール目指して突進する
2	C 大阪	17096	0:09:30.400	敵 1(左から 3 列目下部)	選手 B から D(2 列目下部) へのパスコースをつぶすために進路に立ちふさがる
2	C 大阪	17103	0:09:30.630	B(左から 4 列目中央)	D(左から 2 列目下部) へのコースが無理だと判断し走ってきていた C(B と同列下部) へ横パス
2	C 大阪	17138	0:09:31.800	D(左から 3 列目中央)	敵 1 と敵 2(左から 3 列目) の背後を走っていく A(左から 3 列目) を確認
2	C 大阪	17138	0:09:31.800	敵 1(左から 4 列目中央)	C(5 列目中央) から D(3 列目中央) へのパスコースをブロックするため走る
2	C 大阪	17135	0:09:31.700	C(左から 4 列目中央)	B からのパスを受け取る。
2	C 大阪	17171	0:09:32.900	C(ゴールから右に 4 列目中央)	D(2 列目中央) へパス
2	C 大阪	17191	0:09:33.570	D(ゴールから右に 1 列目中央)	C からのパスを受け取る。
2	C 大阪	17223	0:09:34.640	D(ゴールから左に 1 列目中央)	A(同列中央) にパス、(その後敵の一人と衝突)
2	C 大阪	17244	0:09:35.340	A(ゴールから左に 2 列目中央)	ボールを受け取って前方に走り込む
2	C 大阪	17256	0:09:35.740	A(ゴールから左に 2 列目中央)	走っている最中に E(ゴールから右に 1 列目下部) を確認
2	C 大阪	17256	0:09:35.740	A(ゴールから左に 2 列目中央)	相手選手が多く集まっている右サイドでなくフリーになっている E へのパスを決定
2	C 大阪	17287	0:09:36.770	A(ゴールから左に 3 列目中央)	選手 E(2 列目下部) の前方スペースにパス(A は敵 5 人に囲まれ厳しい状態)
2	C 大阪	17290	0:09:36.870	E(ゴールから左に 2 列目下部)	A からのボールを追って走りこむ
2	C 大阪	17390	0:09:40.210	E(ゴールから左に 2 列目下部)	A からのパスを受けてシュート (失敗)
2	C 大阪	17430	0:09:41.540	E(ゴールから左に 2 列目下部)	シュート
3	川崎 F	17778	0:09:53.150	A(ゴールから左に 3 列目上部)	前方の選手 B(2 列目上部) の前のスペースにパス
3	川崎 F	17822	0:09:54.620	B(ゴールから右に 1 列目上部)	斜め前方の C(3 列目下部) の位置を確認
3	川崎 F	17845	0:09:55.390	B(ゴールから右に 2 列目上部)	A からのパスボールを確保
3	川崎 F	17857	0:09:55.790	B(ゴールから右に 3 列目上部)	斜め前方の C(4 列目中央) のスペースにパス
3	川崎 F	17927	0:09:58.130	C(右から 4 列目中央)	B からのボールを確保
3	川崎 F	17942	0:09:58.630	C(右から 4 列目中央)	右ななめ前方の選手 D(同列目下部) の前方スペースにパス
3	川崎 F	17994	0:10:00.360	D(右から 2 列目下部)	シュート (キーパーに阻まれ失敗)

4	川崎 F	35427	0:19:42.040	A(右から 5 列目中央)	敵と味方がもみ合っているところから左
4	川崎 F	35451	0:19:42.840	C(右から 3 列目中央)	サイドの選手 B(同列上部) にボールを逃がす
4	川崎 F	35465	0:19:43.310	D(右から 3 列目上部)	自分へのパスを予測して小走りで走り出す
4	川崎 F	35469	0:19:43.450	B(左から 4 列目上部)	前方へ走り出す
4	川崎 F	35506	0:19:44.680	敵 1(右から 3 列目上部)	A からのパスを受け取る
4	川崎 F	35501	0:19:44.510	B(右から 5 列目上部)	B(右 5 列上) から D(右 3 列上) へのパスコースを
4	川崎 F	35509	0:19:44.780	C(右から 3 列目中央)	予測しそれをつぶすためにコースの入り込む
4	川崎 F	35533	0:19:45.580	C(右から 4 列目中央)	C(B より右へ 2 列先中央) へパス
4	川崎 F	35552	0:19:46.210	D(右から 4 列目中央)	B(5 上) と D(右 2) の方向に体を開きフリー
4	川崎 F	35561	0:19:46.510	E(右から 2 列目上部)	スペースでパスを待つ
4	川崎 F	35571	0:19:46.850	敵 2(右から 1 列目中央)	B からのボールを受けて間髪を入れずに
4	川崎 F	35604	0:19:47.950	F(ゴールから右に 1 列目中央)	D(右 3 上) へとパスを回す
4	川崎 F	35619	0:19:48.450	D(ゴールから右に 1 列目中央)	C からのパスを受け取る
4	川崎 F	35659	0:19:49.780	D(左から 4 列目中央)	相手ゴールに向かって走り出す
4	川崎 F	35671	0:19:50.190	D(左から 3 列目中央)	(選手 F をけん制していた (?)) が危機を感じて
4	川崎 F	35714	0:19:51.620	E(左から 3 列目中央)	自陣のゴール方向へ駆け出す
4	川崎 F	35737	0:19:52.390	敵 2(左から 4 列目中央)	相手ゴールに向かって走り出す
4	川崎 F	35791	0:19:54.190	E(右から 3 列目上部)	ほぼ敵の一人と並んだ状態で敵陣のゴールを
4	川崎 F	35809	0:19:54.790	E(右から 3 列目上部)	目指してドリブル
					敵三人に囲まれた状態で、隣にすぐ敵がいる
					ため一番近くの F
					へのパスを断念
					敵のプレスが高まってきたため、左サイドで
					フリーの E にパス (足元, オフサイドを懸念 (?))
					D からのボールを確保
					ボールを追うのをやめ、ゴールを守るため
					ゴール間近に移動
					ボールをコントロールして敵の DF を巻こう
					とする
					シュート, しかしコントロールしている間
					に敵がゴールに集まってしまったため
					うまく狙えずミス

5	C 大阪	69161	0:38:27.640	C(左から 2 列目中央)	A のキックを予測, 防御から攻撃に転じる
5	C 大阪	69176	0:38:28.140	A(左から 3 列目中央)	敵選手が胸でトラップしたボールを左前の選手
5	C 大阪	69176	0:38:28.140	B(左から 3 列目下)	B(同列下部) にパス
5	C 大阪	69176	0:38:28.140	敵 1(左から 1 列目中央)	A からのパスを予測し, C とコンタクトをとり C へ
5	C 大阪	69256	0:38:30.810	B(ゴールから右に 1 列目下部)	のコースを意識
5	C 大阪	69340	0:38:33.610	B(ゴールから左に 3 列目下部)	選手 C を警戒しつつその前につきながら前進
5	C 大阪	69373	0:38:34.710	B(ゴールから左に 3 列目下部)	A からのボールを確保
5	C 大阪	69379	0:38:34.910	敵 1(右から 5 列目上部)	敵二人をドリブルでかわしつつ中央へ (一人目)
5	C 大阪	69386	0:38:35.140	C(左から 5 列目上部)	敵二人をドリブルでかわしつつ中央へ (二人目)
5	C 大阪	69399	0:38:35.580	C(左から 4 列目上部)	C(同列上部) を確認して警戒, マーク
5	C 大阪	69400	0:38:35.610	B(右から 3 列目中央)	B に右手を挙げて合図
5	C 大阪	69417	0:38:36.180	敵 1(左から 5 列目中央)	B からのパスを想定して前方にダッシュ
5	C 大阪	69458	0:38:37.550	C(左から 3 列目中央)	敵の間で C(右から 6 列目上部) の前のスペース
5	C 大阪	69477	0:38:38.180	C(左から 3 列目中央)	にパス
					C の突然の走り込みに対応できずあわてて
					方向転換し追跡
					B からのパスボールを確保
					敵 DF がブロックするときにそのまま滑り込み
					シュート, そしてゴール