



Title	サッカー映像における戦術解析を実現するための深層学習に関する研究
Author(s)	鈴木, 元樹
Citation	北海道大学. 博士(情報科学) 甲第14577号
Issue Date	2021-03-25
DOI	10.14943/doctoral.k14577
Doc URL	http://hdl.handle.net/2115/81107
Type	theses (doctoral)
File Information	Genki_Suzuki.pdf



[Instructions for use](#)

博士論文

サッカー映像における戦術解析を
実現するための深層学習に関する研究



北海道大学 大学院情報科学院
情報科学専攻

鈴木 元樹

2021年3月

目次

第1章 序論	1
1.1 本研究の背景	1
1.2 本研究の目的	3
1.3 本論文の構成	3
第2章 サッカー映像からの戦術解析に関する従来研究	5
2.1 はじめに	5
2.2 個人戦術解析に関する従来研究	8
2.3 グループ戦術解析に関する従来研究	10
2.4 チーム戦術解析に関する従来研究	11
2.5 本論文で解決すべき課題と解決方法	13
2.6 まとめ	15
第3章 Deep Extreme Learning Machine に基づくチーム戦術の推定	16
3.1 はじめに	16
3.2 選手位置データからのフォーメーション特徴量の算出	17
3.2.1 選手陣形の変化に関する特徴量	18
3.2.2 選手の移動に関する特徴量	19
3.3 Deep Extreme Learning Machine による基本戦術の推定	21
3.4 実験	25
3.4.1 実験条件	25
3.4.2 実験結果	28
3.5 まとめ	28

第4章	チームの戦術の関係性に基づく制約を導入したチーム戦術の推定	30
4.1	はじめに	30
4.2	前処理：フォーメーション特徴量の算出	33
4.3	DELMに基づく基本戦術の推定値の算出	33
4.4	チームの戦術の関係性に基づく基本戦術の推定結果の補正	36
4.4.1	2チームの戦術の関係性に基づく基本戦術の組み合わせの 算出	36
4.4.2	ボール保持率を用いた試合状況の変化に基づく推定結果の 更新	37
4.5	実験	40
4.5.1	実験条件	40
4.5.2	実験結果	44
4.6	まとめ	49
第5章	サッカー映像視聴時の経験者の視線データを用いた戦術解析	50
5.1	はじめに	50
5.2	選手ネットワークの生成	53
5.2.1	先着領域に基づくエッジ重みの算出	53
5.2.2	推定された注視位置に基づくエッジ重みの算出	55
5.3	HITS アルゴリズムに基づく選手の重要度の推定	61
5.4	実験	62
5.4.1	実験条件	62
5.4.2	実験結果	64
5.5	まとめ	72
第6章	結論	73
6.1	本研究の総括	73
6.2	本研究の今後の課題	74
	謝辞	75

参考文献	77
著者の研究業績	93

目次

1.1	本研究における課題とその解決方策, および章構成の関係	4
2.1	研究マップ	7
3.1	15つに分割されたサッカーフィールド	19
3.2	DELM の概要	22
3.3	提案および比較手法によって得られた基本戦術の推定結果	29
4.1	提案手法の概要. 前処理として特徴量の算出を行う (4.2). 提案手法では, 2つの段階により構成されている. まず, 第一段階では, DELM に基づき基本戦術の推定値を算出する (4.3). 続いて, 第二段階では, チームの戦術の関係性とボール保持率に基づき基本戦術の推定結果を補正する (4.4).	32
4.2	ボールの保持率に基づいた推定結果の更新方法	39
4.3	提案および比較手法における基本戦術の推定結果	47
5.1	提案手法の概要. 提案手法では, 2つの段階から構成される. まず, 第一段階では, 先着領域 (5.2.1) と注視位置推定モデル (5.2.2) に基づく選手ネットワーク (5.2) を生成する. 続いて, 第二段階では, HITS アルゴリズムを用いた重要度の推定 (5.3) を行う.	52
5.2	先着領域の例	55
5.3	LSTM のネットワーク構造	58
5.4	先着領域および推定された注視位置に基づいて生成されたネットワークの例	60
5.5	提案手法の α を変化させた場合の Recall@k	66

5.6	入力フレームと比較手法（IM）から得られた重要度の推定結果 . . .	68
5.7	提案手法と比較手法（CM1）から得られた重要度の推定結果 . . .	69
5.8	比較手法（CM2およびCM3）から得られた重要度の推定結果 . . .	70
5.9	比較手法（CM4）から得られた重要度の推定結果	71

表目次

3.1	基本戦術の概要 [1]	17
3.2	フォーメーション特徴量の概要	18
3.3	実験で用いたデータの詳細	26
3.4	提案手法で用いたパラメータの詳細	27
3.5	各手法の再現率 (Recall), 適合率 (Precision), および F 値	28
4.1	2 チームにおける戦術の関係性. Ret, FC, Set, Poss, Sw はそれぞれリトリート, フォアチェック, セットプレイ, ビルドアップ, 速攻を示す.	31
4.2	実験で用いたデータの詳細	42
4.3	提案手法で用いたパラメータの詳細	43
4.4	提案および比較手法 8 を 50 試行した際の平均と分散	44
4.5	提案および比較手法における基本戦術推定の精度. R, P, F はそれぞれ再現率 (Recall), 適合率 (Precision), および F 値を示している.	45
4.6	提案手法における基本戦術の最適な組み合わせに基づく 補正を適用する前 の推定結果から得られた混同行列. これらの結果は, 比較手法 8 と対応する. Gt は Ground-truth を表す.	48
4.7	提案手法における基本戦術の最適な組み合わせに基づく 補正を適用した後 の推定結果から得られた混同行列. これらの結果は, 提案の結果と一致する. Gt は Ground-truth を表す.	48
5.1	特徴量と Ground-truth の詳細	56
5.2	提案手法で用いたパラメータの詳細	64

5.3	各手法の Recall@ k	65
5.4	「推定された注視位置と実際の注視位置の差」と「選手の重要度 推定の成否」の関係	67

第1章 序論

1.1 本研究の背景

近年、スポーツ映像はテレビ放送に加えてインターネットによる映像配信サービスにより視聴可能となっている¹。これに伴い、DAZNに代表されるスポーツ競技を対象とした映像配信サービスでは、チームや選手に関する情報などが、映像とともに提供されている。特に、サッカー競技の市場規模は団体スポーツ競技の中で最も大きく [2]、競技に関する知識量が視聴者によって大きく異なることから、視聴者の理解を助ける情報の生成に関する技術が必要であり、その実現のための研究が活発に進められている [3–8]。視聴者がサッカー映像の内容を十分に理解するためには、選手や競技ルールに加えて、選手の動きやフォーメーションなどの戦術に関する専門知識が必要となる。したがって、視聴者のサッカー競技への理解を促すためには、サッカー映像からの戦術解析技術の構築が必要不可欠である。

サッカー競技で用いられる戦術は主に、個人戦術、グループ戦術、およびチーム戦術の3つに大別される [1,9]。まず、個人戦術はシュートやドリブルなどの個人に着目した戦術である。グループ戦術は、パスやオフサイドトラップなど、攻撃と守備において複数の選手が連携することで行われる戦術である。最後に、チーム戦術は、チームメンバー全員で個人戦術またはグループ戦術を用いて攻撃や守備を行う戦術であり、試合状況に応じて変化する。従来より、サッカー映像から選手やボールを抽出し、個人戦術またはグループ戦術の推定を可能にする手法が提案されている [10–22]。また、近年、実際のスタジアムに設置されたセンサ²により多くの選手・ボール位置データが高精度に取得可能となったことか

¹<https://www.dazn.com/>や <https://www.hulu.jp/>など

²TRACAB image tracking system (<https://chyronhego.com/products/sports-tracking/>)

ら、個人・グループ戦術に加えて、チーム戦術を推定する研究の注目度が高まっている。チーム戦術は試合状況に応じて複雑に変化するため、学習データから自動で識別器の構築が可能な機械学習による解析が行われてきた [23–30]。具体的に、選手・ボールの位置に関するデータから算出した選手・ボールの動きに関する特徴と、専門家が付与したチーム戦術に関するラベル情報を組とした学習データを用いて、チーム戦術の推定を可能にする識別器の構築が行われている。さらに近年では、深層学習に関する研究が活発に行われており [31–34]、その導入によるチーム戦術推定の高精度化が期待されている。

深層学習は多層のニューラルネットワークによる機械学習手法であり、入力データと対応する出力ラベルの組を用いて入力データの特徴を学習することで、隠れ層のパラメータが決定される。深層学習の精度向上には、一般に多数の隠れ層が必要であり、最適に決定すべきパラメータ数が多くなるため、大量の学習データが必要となる。しかしながら、チーム戦術は個人・グループ戦術よりも専門性が高いため、学習データの出力ラベルの付与には膨大な時間と労力を要し、十分な量のデータを収集することは困難である。加えて、選手や監督の入れ替わりによりサッカー戦術が変化することから、対象のチームの選手・ボール位置データを大量に取得可能となった場合においても、そのデータの全てをチーム戦術推定に用いることが難しい。このため、深層学習に基づいた戦術解析については、未だ高精度なチーム戦術の推定手法が実現されていない。

これまでに、深層学習の分野では学習データ量が不足する場合、学習データを加工・変形させ、データ量を人工的に充足するデータ拡張手法 [31,32,34,35] や、他のデータで学習を行った深層学習のモデルに対して対象分野のデータを追加し学習を行う転移学習 [36–38] など、少量データからの学習を行う手法が様々提案されてきた。しかしながら、サッカー競技における戦術解析を対象とした場合、単純な処理によって学習データを充足することは容易ではなく、また、転移学習を行うための他の学習データにより構築されたモデルも存在しない状況にある。

1.2 本研究の目的

本論文では、少ない学習データ量においてもサッカー映像における戦術解析を可能とする新たな深層学習手法を提案する。具体的に、少量データからの学習を可能にする手法の導入を行い、その後、戦術等のサッカー競技に関する知識の導入に基づく高度化を行うことで、深層学習に基づいた高精度なチーム戦術の推定を実現する。本論文では、1) フィードフォワード型学習の導入によって少量の学習データにおいてもモデルパラメータの最適化を可能にする深層学習手法の実現、2) チームの戦術の関係性に基づく推定の高精度化、3) サッカー経験者の競技に関する専門知識に基づく戦術解析の実現の3つのアプローチにより、従前に存在した問題の解決を試みる。まず、1) では、誤差逆伝搬法に基づかず、大量の学習データを必要としない識別器 Deep Extreme Learning Machine (DELM) [39] を戦術解析に導入し、選手・ボール位置データから算出したチーム戦術に関する特徴を用いて学習を行う。これにより、少量の学習データ量においても DELM のパラメータが最適化され、従来のチーム戦術の推定手法と比較して高精度化が実現されることを示す。次に、2) では、1) で構築した深層学習手法に、新たにチームの戦術の関係性に基づいた制約を導入することで戦術に関する専門知識に基づいて戦術の推定結果を補正する。これにより、対戦する2チームの戦術の組み合わせに基づく最適な補正が可能となり、チーム戦術推定の高精度化が実現される。最後に、3) では、サッカー映像を視聴する経験者の視線の動きが競技に関する専門知識と高い関連性を有していることに着目し [40,41]、これを深層学習に導入する。以上のように、本論文では、戦術や競技に関する専門知識を導入した深層学習を構築することで、少量の学習データからの戦術解析を実現する。上記の本研究における課題とその解決方策および章構成の関係を図 1.1 に示す。

1.3 本論文の構成

本論文は、6章から成り、以下に各章の概要を述べる。第1章では、研究背景と目的について述べた。第2章では、本研究の関連研究としてサッカー映像からの

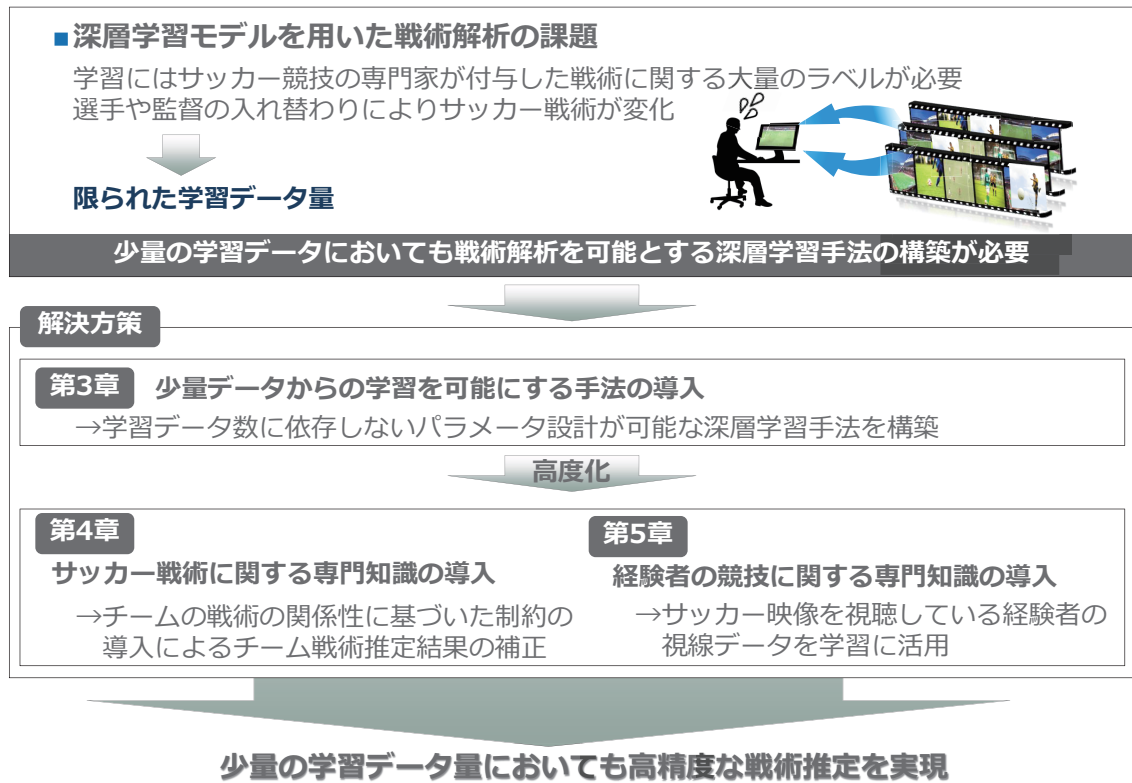


図 1.1: 本研究における課題とその解決方策, および章構成の関係

戦術解析に関する従来研究を紹介し, 本論文で解決すべき課題を明らかにする. 第3章では, DELMに基づいて少量の学習データから高精度なチーム戦術の推定を可能にする手法を提案する. 第4章では, チームの戦術の関係性に基づく制約を導入したチーム戦術の推定手法を提案し, 推定結果の補正に基づく高精度化が実現されることを示す. 第5章では, サッカー経験者から取得した映像視聴時の視線データを用いた戦術解析手法を構築することで, サッカー競技に関する専門知識を導入することの有効性を示す. したがって, 少量データからの学習を可能にする深層学習モデルを構築することで, サッカー映像からの高精度な戦術解析をする. 第6章では, 本論文の結論を示し, 今後の課題について述べる.

第2章 サッカー映像からの戦術解析 に関する従来研究

2.1 はじめに

本章では、サッカー映像において戦術解析を行う従来研究を説明する。これまでに、スポーツ映像の解析では、サッカーやバスケットボール、テニスなどの様々な映像を解析する研究が行われてきた [10–30, 42–78]。図 2.1 にスポーツ映像解析の従来研究のマップを示す。2010 年頃までは、基本的な画像・音響信号解析に基づく映像の解析に着目した研究が種々行われてきた。具体的には、選手やボールの検出・追跡手法 [42–47] や映像要約、および映像検索・シーン検出手法 [53–60, 63–67] などの手法が種々提案されている。2011 年以降は、実際のスタジアムに設置されたセンサ¹により多くの選手・ボール位置データが高精度に取得することが可能となったことに伴い、この位置データの活用による映像中の選手やチームの行動に着目した映像解析が多く行われている。特に各スポーツ競技の戦術に関する解析が多く行われ、位置データを用いて機械学習により様々な戦術が解析されてきた [10–30, 73–78]。また、基本的な映像解析においても 2011 年以降も継続的に研究が進められており、ミニブログの Twitter² から取得した試合映像に関する投稿文章を用いて映像を要約する手法 [61] や深層学習を用いた映像解析手法も種々提案されている [48–52, 62]。これらの手法によって、基本的な映像解析では精度向上が実現された。

以降では、本論文と強く関連しているサッカー映像の戦術解析に関する従来研究を説明する。本章の構成を以下に示す。2.2 では、個人戦術解析に関する従来

¹TRACAB image tracking system (<https://chyronhego.com/products/sports-tracking/>)

²<https://twitter.com/>

研究を説明する。2.3では、グループ戦術解析に関する従来研究を説明する。2.4では、チーム戦術解析に関する従来研究を説明する。2.5では、従来研究より考えられる課題と本論文の解決方法を示す。

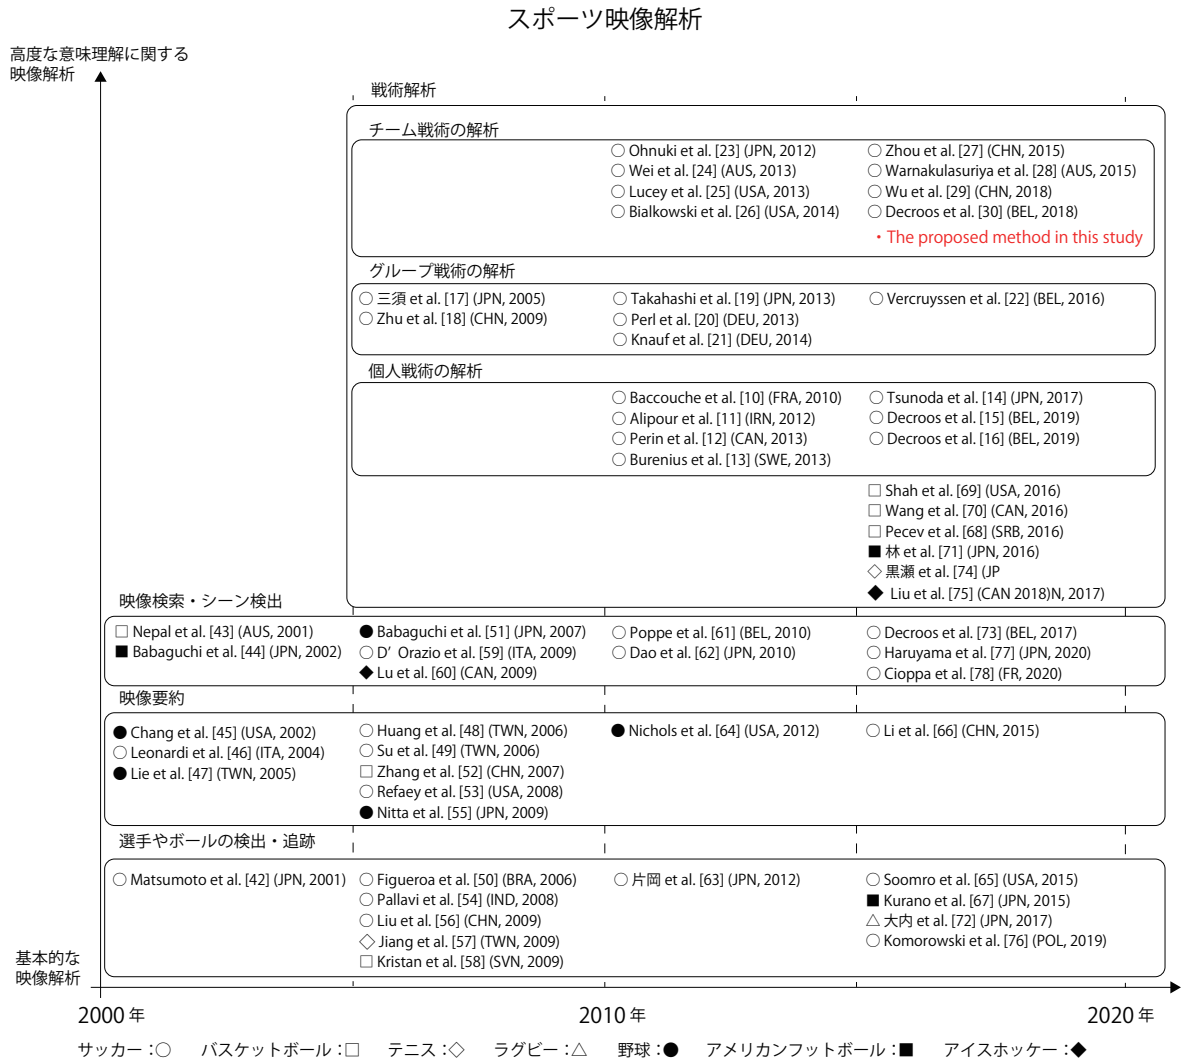


図 2.1: 研究マップ

2.2 個人戦術解析に関する従来研究

これまでに、個人戦術を解析する手法が種々提案されている [10–16]. これらの手法では、サッカー映像に対して画像解析や音響信号解析を適用することで、シュートやドリブルシーンなどを検出可能としている. 加えて、CNN ネットワークをはじめとした近年の深層学習技術の発展により、サッカー映像に撮像される選手の骨格に関する情報を高精度に取得可能となったため、シュートやドリブルのフォーム解析も行われている. 以降では、これまでに取り組みが行われてきた個人戦術を解析する手法についてそれぞれ説明を行う.

文献 [10]

文献 [10] では、深層学習手法の一つである、Long Short-Term Memory (LSTM) [79] を用いて個人戦術の分類を行っている. 本手法により、ゴールキックやシュートシーンを高精度に分類することを可能とした.

文献 [11]

選手がシュートするシーンを検出する手法が提案されている. 特に、サッカー映像から画像および音響特徴量を算出して、ベイジアンネットワーク [80] により高精度にシュートシーンを検出した.

文献 [12]

文献 [12] では、個人の選手に着目してその選手の走行距離や、パス回数などサッカー競技の統計的なデータを用いて解析および可視化を行っている.

文献 [13]

多視点カメラにより得られたサッカー映像から個人戦術を行う際の選手の3次元姿勢を推定している. 具体的に、多視点の映像より関節の位置をベイジアンネットワークに基づきそれぞれ検出し、関節角度の制約に基づいた人の骨格に関するモデル生成により、姿勢推定が可能となった. これにより、一般的な CNN に基づく姿勢推定手法 [81] と比較して、高精度な推定が実現された.

文献 [14]

サッカー映像に撮像される複数選手の個人戦術を、階層的な LSTM に基づいて分類している。具体的に、第一段階において、撮像される各選手ごとに LSTM を構築しパスやシュート、およびドリブルなど個人が行っている行動を分類する。第二段階において、各 LSTM の出力を統合してボールの画像特徴量に加えて新たな LSTM に入力することにより、個人戦術の高精度な分類が可能となった。これにより、通常の LSTM に基づく分類手法 [82] と比較して、高精度化を実現した映像に撮像される選手数の増加による遮蔽に対しても頑健に分類を可能とした。

文献 [15]

ボール位置のイベントデータを用いて、個人戦術を用いる各選手の評価を定量的に行っている。イベントデータはパス、ドリブル、ファウル、およびシュート等の行動が発生した時刻とその行動を行った選手の ID により構成され手動で作成されている。具体的に、イベントデータから選手の行動により得点および失点となる確率をそれぞれ算出し、確率値を各イベントに関する特徴量として用いる。その後、機械学習手法の一つである CatBoost [83] を用いて確率値の算出を行うことで選手の評価が行われる。本手法により、ロジスティック回帰やランダムフォレストなどの一般的な機械学習手法 [84] よりも高精度に確率値が算出可能となった。

文献 [16]

イベントデータを用いて、個人戦術を用いる選手のプレースタイルを分析している。具体的に、各フィールド位置において個人戦術を用いた頻度をそれぞれ算出し、非負行列因子分解 [85] に基づき次元削減を行うことで、選手の特徴ベクトルを構築する。本手法により、多様な選手のプレースタイルに関するデータを特徴ベクトルとして構築することが実現され、機械学習によるチーム戦術の分析に対する応用が示唆された。

2.3 グループ戦術解析に関する従来研究

これまで、グループ戦術を解析する手法が種々提案されている [17-22]。これらの手法では、個人戦術解析と同様にサッカー映像に対して画像解析や音響信号解析を適用することで解析が行われてきた。これにより、オフサイドトラップ [1] のオフサイドライン検出など、映像に撮像される複数の選手位置の活用によりグループ戦術を解析することが可能となった。また、選手・ボール位置データの取得技術の発展に伴い、映像に撮像される選手・ボールの位置を2次元空間上に変換した位置データを機械学習を用いて分析することにより、パスの可能領域や攻撃的戦術を使用する選手のクラスタリング等を実現可能としている。以降では、これまでに組み込まれてきたグループ戦術の解析手法についてそれぞれ説明を行う。

文献 [17]

文献 [17] では、グループ戦術の一つであるオフサイドトラップのオフサイドラインを検出する手法を構築した。本手法では、サッカー映像中の選手の位置座標を算出し、さらに色に関する情報に基づきチームの分類を行う。次に、チームのフォーメーションを解析することで、オフサイドラインを高精度に検出可能とした。

文献 [18]

チームの攻撃シーンにおける選手の攻撃パターンに関する分析が行われている。本手法では、パターン認識技術に基づいて攻撃の方向や攻撃を行っているフィールドの位置を算出することで、攻撃シーンのチームの攻撃パターンを明らかとした。

文献 [19]

文献 [19] では、サッカー映像におけるパスが可能な領域の算出手法が提案されている。本手法では、選手およびボールの位置を用いて、エネルギー最小化原理に基づいた、動的な3次元の格子モデルの Active Grid [86] によりパス可能領域推定を実現する。

文献 [20]

文献 [20] では、グループ戦術に注目した戦術推定手法とその推定結果を可視化する解析システムを構築している。特に、複数の選手により構成されるグループのフォーメーションとその位置に基づいてパターン認識によりグループ戦術を推定する。さらに、推定されたグループ戦術と併せて1試合の選手位置、選手のスピードやグループのフォーメーションの変化などの統計的なデータ分析をシステムにより可能としている。

文献 [21]

選手・ボール位置データを用いて、グループ戦術を行っている選手をクラスタリングする手法である。具体的に、選手位置の軌道を用いてカーネル化した K-Medoids 法 [87] に基づき選手のクラスタリングを行う。これにより、集合間の距離を示すハウズドルフ距離に基づいて各選手をクラスタリングする手法 [88] と比較して、攻撃的な選手と守備的戦術を行う選手群の高精度なクラスタリングを実現した。

文献 [22]

選手・ボールの位置データから、パスの受け手を予測する手法を構築している。具体的に、選手・ボールの位置と選手の移動ベクトルから各選手の支配領域 [89] を算出し、その時間変化から各選手がボールの受け手となる確率値を定性的空間表現 [90] に基づき予測する。これにより、パスの受け手を 42% で予測可能とした。

2.4 チーム戦術解析に関する従来研究

これまで、チーム戦術を解析する手法が種々提案されている [23–30]。上記の手法は、主に選手・ボールの位置データやイベントデータを用いてチームの戦術が解析されている。多くの文献では、位置データやそのデータから算出した特徴と専門家によって付与されたチーム戦術に関するラベルを用いて機械学習手法の一つであるクラスタリングを適用することにより、チーム戦術の分類が可能となっ

ている。また、対象チームの1年間のイベントデータからチーム戦術の使用頻度等の分析により、チームごとのプレースタイルを明らかとする研究も種々行われている。以降では、従来のチーム戦術の解析手法についてそれぞれ説明を行う。

文献 [23]

文献 [23] では、チーム戦術を推定する手法が構築されている。本手法では、選手位置から取得されるフォーメーションに関する特徴量を用いて教師なし機械学習手法の Fuzzy C-means [91] によりチーム戦術推定を実現する。

文献 [24]

文献 [24] では、選手・ボールの時系列データを用いたクラスタリングによるセットプレイの分類手法が構築されている。本手法により、セットプレイに分類されるコーナーキック、フリーキック、スローイン等の高精度な分類が実現された。

文献 [25]

イベントデータを用いてチームのk近傍法 [92] に基づきチーム戦術を分類している。1年間のプレミアリーグのチームのイベントデータを分析することで、ホームでプレーしているチームはボールの保持率が高く、シュート数や得点数がアウェーの試合と比較し多くなることが明らかとなっている。

文献 [26]

文献 [26] では、選手・ボール位置データに基づくフォーメーションを視覚化する手法が構築されている。本手法によって、試合の戦況を視覚的に把握可能な情報提示が実現された。

文献 [27]

文献 [27] では、選手がパスを行い連携を取りながら攻撃を行っているフィールド領域を判別分析に基づき分類を行い、フィールド領域を用いて機械学習により戦術の分類を行った。

文献 [28]

選手・ボール位置データを用いて、チーム戦術をクラスタリングにより分類することでゴールとなる期待値を各時刻で算出している。具体的に、k-means [93]に基づきチーム戦術の分類を行い、その値を用いて Expected Goal Value Model (EGV モデル) [94]に基づき、各選手で期待値を算出する。これにより、様々なチームの得点シーン時の選手移動に関する類似度を算出可能としている。

文献 [29]

文献 [29] では、選手位置の時系列変化を用いて選手間の連携をネットワークとして表現している。これにより、サッカー映像の攻撃や守備シーンを高精度に検出することを可能とした。

文献 [30]

ボール位置のイベントデータを用いて、ゴールキック、コーナーキック、およびセットプレイ等のチーム戦術を自動分類する手法を構築している。具体的に、イベントデータからチームが攻撃および守備を行っている区間を分割し、分割されたイベントデータをクラスタリングによりチーム戦術の分類を行っている。本手法により、試合で用いられる各チーム戦術の割合が算出となり、様々なチームのプレースタイルを明らかとした。

2.5 本論文で解決すべき課題と解決方法

本節では、少ない学習データ量においてもサッカー映像におけるチーム戦術の解析を可能とする新たな深層学習技術を実現を目的として、本論文で解決すべき課題を明確にする。先に述べた従来研究では、サッカー戦術を解析を行うために、様々な手法が構築されている。2.2 では、個人戦術の解析を行うために、特に映像に撮像される選手に着目した映像解析が行われている。また、深層学習等の機械学習技術の発展により、これらの手法を適用することで個人戦術を行う選手のフォーム等を解析することが可能となった。次に、2.3 では、グループ戦術を解析するために、サッカー映像に加えて選手・ボールの位置データを用いた解析が

種々行われている。サッカー映像に撮像される選手の位置に着目した解析や、選手・ボール位置データを用いた機械学習に基づくグループ戦術の解析を可能とした。次に、2.4では、チーム戦術を解析するために、主に選手・ボール位置データを用いて機械学習手法の一つであるクラスタリングが行われている。特に、これらの手法では、選手・ボールの位置に関するデータから算出した選手・ボールの動きに関する特徴と、専門家が付与したチーム戦術に関するラベル情報を組とした学習データを用いて、チーム戦術の解析を可能としている。しかしながら、チーム戦術は個人およびグループ戦術よりも専門性が高く選手の位置が複雑となるため、学習データの出力ラベルの付与には、膨大な時間および労力を要し、十分なデータ量を確保することが困難である。このため、チーム戦術を深層学習に基づき解析する手法は現在提案されておらず、機械学習を用いたチーム戦術解析の精度の向上には、限界が存在する。これまでに、深層学習の分野では学習データ量が不足する場合、学習データを加工・変形させ、データ量を人工的に充足するデータ拡張手法 [31,32,34,35] や、他のデータで学習を行った深層学習モデルに対して、対象分野のデータを追加しパラメータの最適化を行う転移学習 [36–38] など、少量データからの学習を可能とする手法が様々提案されている。しかしながら、解析対象をチーム戦術とした場合、単純な処理によって学習データを充足することが困難であり、また、転移学習を行うための他の学習データにより構築されたモデルも存在しない状況にある。

そこで本論文では、少ない学習データ量においてもサッカー映像における戦術解析を可能とする新たな深層学習手法を提案する。具体的に、少量データからの学習を可能にする深層学習手法の導入および、戦術に関する知識の導入によって、深層学習に基づいたチーム戦術の高精度な推定が可能になると考えられる。まず、3章で、少量データにおいてもモデルパラメータの最適化を行う深層学習に基づいた手法を構築することで、チーム戦術の推定が高精度化されることを示す。続いて、4章では、3章で構築した手法に対して、新たに戦術に関する知識としてチームの戦術の関係性に基づく制約を導入することで、戦術に関する知識がチーム戦術推定に有効であることを示す。さらに、5章で、戦術に関する知識

としてサッカー経験者から取得した映像視聴時の視線データを用いて深層学習モデルを構築し戦術の解析を行うことで、サッカー競技に関する専門知識を導入することの有効性を示す。実験により、少量の学習データ量においても、高精度にチーム戦術が推定可能となることを確認する。

2.6 まとめ

本章では、本論文と関連したサッカー映像からの戦術解析を行う従来研究に関する説明を行った。加えて、従来研究の課題を述べ、チーム戦術解析の高精度化のために、本論文で解決すべき課題を明確にした。

第3章 Deep Extreme Learning Machineに基づくチーム戦術の推定

3.1 はじめに

本章では，学習データが少量の場合でもモデルのパラメータの最適化を可能とする深層学習手法を実現するため，深層学習手法の一つである Deep Extreme Learning Machine (DELM) [39] に基づき，サッカー映像における基本戦術を推定する手法を構築する．チーム戦術は，主に表 3.1 に示す 5 つの基本的な戦術（以降，基本戦術） [1] に構成される．特に，基本戦術は試合状況に応じて変化する選手の位置や動きによって決定される選手のフォーメーションに基づいてそれぞれ定義されている．DELM は Extreme Learning Machine (ELM) [95] の隠れ層を多層化したフィードフォワード型の深層学習手法である．DELM は学習データが少量の場合においても高精度な識別が可能であるため，本研究に導入することで基本戦術の推定精度の向上が期待できる．これらより，選手のフォーメーションに基づいた特徴量（以降，フォーメーション特徴量） [96] を選手の位置データから算出し，この特徴量を用いた DELM の学習により基本戦術の高精度な推定が実現される．

そこで，本文では，DELM を用いた基本戦術の推定手法について述べる．具体的に，まず，選手位置データからフォーメーション特徴量を算出する．次に，フォーメーション特徴量を用いて DELM を学習することで基本戦術の推定を行う．以上により，少量データを用いた基本戦術の推定モデルの構築が可能となり，高精度な基本戦術推定が実現される．

なお、表 3.1 のセットプレイは、主にボールを止めた後、審判がホイッスルを吹くことで行われるイベントである。ホイッスル音の検出手法 [97] とボールの追跡手法 [98] を用いることで、セットプレイを高精度に検出することが可能となっている。既存の手法によりサッカー映像からセットプレイを個別に検出することが可能となっているため、本論文では、「リトリート」、「フォアチェック」、「ビルドアップ」、および「速攻」の4種類の基本戦術の推定に焦点を当てた。

以降、3.2 で、選手の位置データからフォーメーション特徴量を算出し、3.3 で、フォーメーション特徴量を用いて DELM を学習することで基本戦術を推定する。続いて 3.4 で、実験を行い、最後に 3.5 で、まとめとする。

表 3.1: 基本戦術の概要 [1]

基本戦術	概要
リトリート (Ret)	自陣で陣形を整えながら守る戦術
フォアチェック (FC)	相手ボールとなった直後に、ボール奪取を試みる守備戦術
セットプレイ (Set)	コーナーキックやフリーキックなどの戦術
ビルドアップ (Poss)	フォーメーションを整えながら、時間をかけて攻撃する戦術
速攻 (Sw)	ボール奪取後に、短い時間で攻撃する戦術

3.2 選手位置データからのフォーメーション特徴量の算出

本節では、表 3.2 に示すフォーメーション特徴の算出について説明する。サッカー競技で使用される基本戦術は選手のフォーメーションに基づいてそれぞれ定義されており、選手の位置や動きに基づいている。フォーメーション特徴量は「選手陣形の変化に関する特徴量」と「選手の移動に関する特徴量」により構成されており、選手の位置や動きを反映している。

以降では、「選手陣形の変化に関する特徴量」および「選手の移動に関する特徴量」の詳細について説明をする。

表 3.2: フォーメーション特徴量の概要

選手陣形の変化に関する特徴量	次元数
選手間の距離とその平均および分散	47
選手間距離の変化量の平均	1
サッカーフィールドの各場所における選手の人数	15
選手の移動に関する特徴量	次元数
選手の移動方向とその平均および分散	24
選手の走る速さとその平均および分散	12
選手の加速度の大きさとその平均値および分散	12
合計	111

3.2.1 選手陣形の変化に関する特徴量

選手陣形の変化に着目した特徴量を算出するために、ゴールキーパーを除いたサッカーフィールド上の選手同士の距離と選手の分布に注目する。各基本戦術はフィールド上の選手位置の分布が異なり、その選手間距離も異なっている。これらの選手間距離と選手の分布は基本戦術に依存するため、基本戦術の推定に有効であると考えられる。具体的に、選手陣形の変化に関する特徴量として「選手間の距離とその平均および分散 \mathbf{u}_{dist} 」, 「選手間距離の変化量の平均 u_{vdist} 」, 「サッカーフィールドの各場所における選手の人数 \mathbf{u}_{area} 」の3種類を算出する。上述したこれらの特徴量は以下に示す式で定義される。

$$\mathbf{u}_{\text{dist}} = [\text{dist}(1), \text{dist}(2), \dots, \text{dist}(45), \text{mean}(\text{dist}), \text{var}(\text{dist})]^T \quad (3.1)$$

$$u_{\text{vdist}} = \text{mv} \quad (3.2)$$

$$\mathbf{u}_{\text{area}} = [\text{area}(1), \text{area}(2), \dots, \text{area}(15)]^T \quad (3.3)$$

ただし、上式において、 $\text{dist}(\cdot)$ は、ゴールキーパーを除いた2人の選手間の距離であり、その選手の組み合わせの総数は45 (${}_{10}C_2 = 45$) となる。また、 $\text{mean}(\cdot)$ と $\text{var}(\cdot)$ は、選手間距離の平均と分散を示す。さらに、 mv は、選手間距離の変化量の平均を示し、 $\text{area}(m)$ ($m = 1, 2, \dots, 15$) は、サッカーフィールドを分割

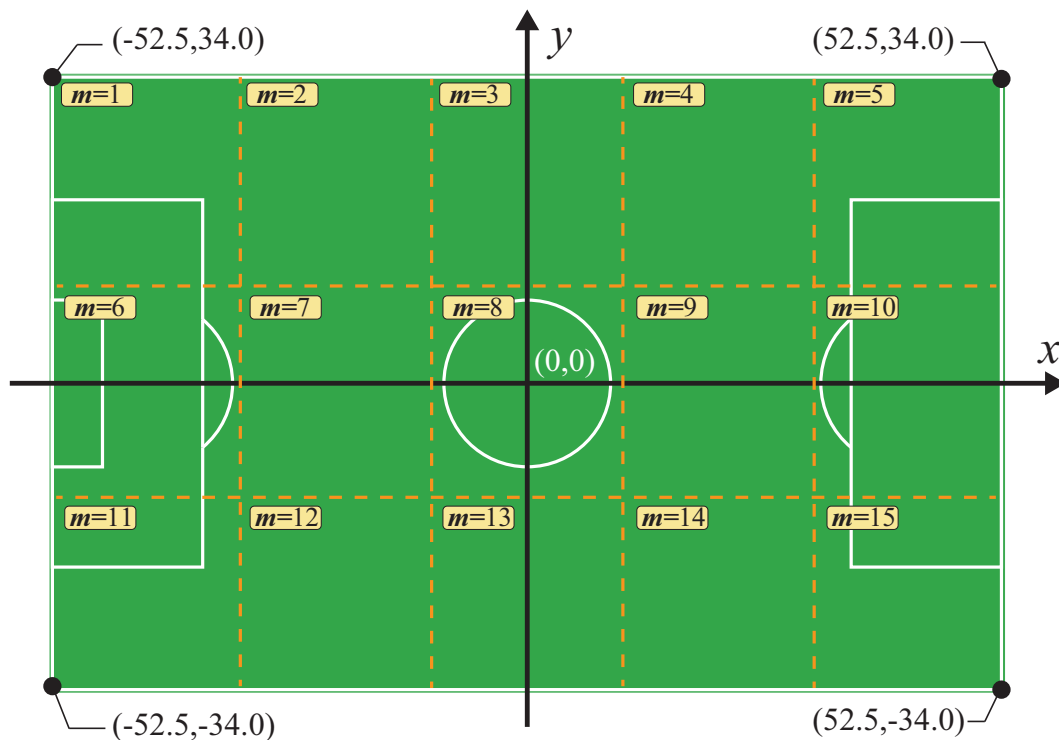


図 3.1: 15 つに分割されたサッカーフィールド

した際に各領域に存在する選手数を示している。本手法では、図 3.1 に示す通りサッカーフィールドを均等な 15 つのエリアに分割している。図において、 x と y はサッカーフィールド内の水平および垂直方向の位置座標軸を示している。また、サッカーフィールドの大きさは国際サッカー連盟（International Federation of Association Football）の規定に従っている [99]。最終的に、 $D_1 (= 47 + 1 + 15)$ 次元の選手陣形の変化に関する特徴量が算出される。

3.2.2 選手の移動に関する特徴量

選手の移動に関する特徴量を算出するために、ゴールキーパーを除いた選手の動きに注目する。具体的に、選手の移動方向、速度、加速度に基づいて特徴を算出する。攻撃と守備の基本戦術において、選手の移動方向など、選手の動きが大

大きく異なる。加えて、フォアチェックでは、選手は素早い動きで守備をすることが多い。また、リトリートは一定速度で守備を行うなど、守備戦術や攻撃戦術同士においても選手の動きが異なるため、選手の移動に関する特徴量は基本戦術の推定に有効である。特に、本手法では選手移動に関する特徴量として、「選手の移動方向とその平均および分散 \mathbf{u}_{mov} 」, 「選手の走る速さとその平均および分散 \mathbf{u}_{vel} 」, 「選手の加速度の大きさとその平均値および分散 \mathbf{u}_{acc} 」の3種類を算出する。上述の特徴量は以下に示す式で定義される。

$$\mathbf{u}_{\text{mov}} = [\text{mov}_x(1), \text{mov}_x(2), \dots, \text{mov}_x(10), \text{mean}(\text{mov}_x), \text{var}(\text{mov}_x), \text{mov}_y(1), \text{mov}_y(2), \dots, \text{mov}_y(10), \text{mean}(\text{mov}_y), \text{var}(\text{mov}_y)]^T \quad (3.4)$$

$$\mathbf{u}_{\text{vel}} = [\text{vel}(1), \text{vel}(2), \dots, \text{vel}(10), \text{mean}(\text{vel}), \text{var}(\text{vel})]^T \quad (3.5)$$

$$\mathbf{u}_{\text{acc}} = [\text{acc}(1), \text{acc}(2), \dots, \text{acc}(10), \text{mean}(\text{acc}), \text{var}(\text{acc})]^T \quad (3.6)$$

ただし,

$$\text{mov}_x(p) = \text{pos}_x(p) - \text{pos}_x^{-1}(p) \quad (3.7)$$

$$\text{mov}_y(p) = \text{pos}_y(p) - \text{pos}_y^{-1}(p) \quad (3.8)$$

$$\text{vel}(p) = \sqrt{\{\text{mov}_x(p)\}^2 + \{\text{mov}_y(p)\}^2} \quad (3.9)$$

$$\text{acc}(p) = \text{vel}(p) - \text{vel}^{-1}(p) \quad (3.10)$$

ここで、 p は選手を表す ($p = 1, 2, 10; 10$ はゴールキーパーを除いた選手数), $\text{pos}_x(\cdot)$ および $\text{pos}_y(\cdot)$ は各選手の x および y 座標の位置, $\text{pos}_x^{-1}(\cdot)$ および $\text{pos}_y^{-1}(\cdot)$ は一フレーム前の位置である。また、 $\text{mov}_x(\cdot)$ および $\text{mov}_y(\cdot)$ は選手の移動方向を示し、 $\text{vel}(\cdot)$ および $\text{acc}(\cdot)$ はそれぞれ選手の走る速さと加速度の大きさを示し、 $\text{vel}^{-1}(\cdot)$ は一フレーム前の速度に対応する。最終的に、 $D_2 (= 24 + 12 + 12)$ 次元の選手の移動に関する特徴量が算出される。

3.3 Deep Extreme Learning Machine による基本戦術の推定

本節では、DELM による基本戦術の推定方法について述べる。本手法では、3.2 で得られた特徴量を活用して DELM の学習を行う。具体的に、「選手陣形の変化に関する特徴量」および「選手の移動に関する特徴量」を結合した特徴ベクトル $\mathbf{x}_i \in \mathbb{R}^{D_1+D_2}$ ($i = 1, 2, \dots, N$; N は映像のフレームの総数) を用いる。図 3.2 では、提案手法で用いる DELM のネットワークが示されている。DELM は Extreme Learning Machine (ELM) [95] の隠れ層を多層化したフィードフォワード型の深層学習手法である。DELM は、1層の入力層、 K 層の隠れ層、1層の出力層の合計 $K+2$ 層により構成されている。学習は第 k 層および第 $k-1$ 層間の重み行列 α^k を逐次計算することより行われる。具体的に、(I) $k = 1, 2, \dots, K$ の重み行列 α^k は教師なし学習手法である Extreme Learning Machine-Auto Encoder (ELM-AE) [39] を各層で構築することにより算出される。一方で、(II) $k = K+1$ の重み行列 α^{K+1} は、ELM と同様に教師あり学習 [95] によって算出される。以降では、上記で述べたそれぞれの重み行列を算出する方法を説明する。

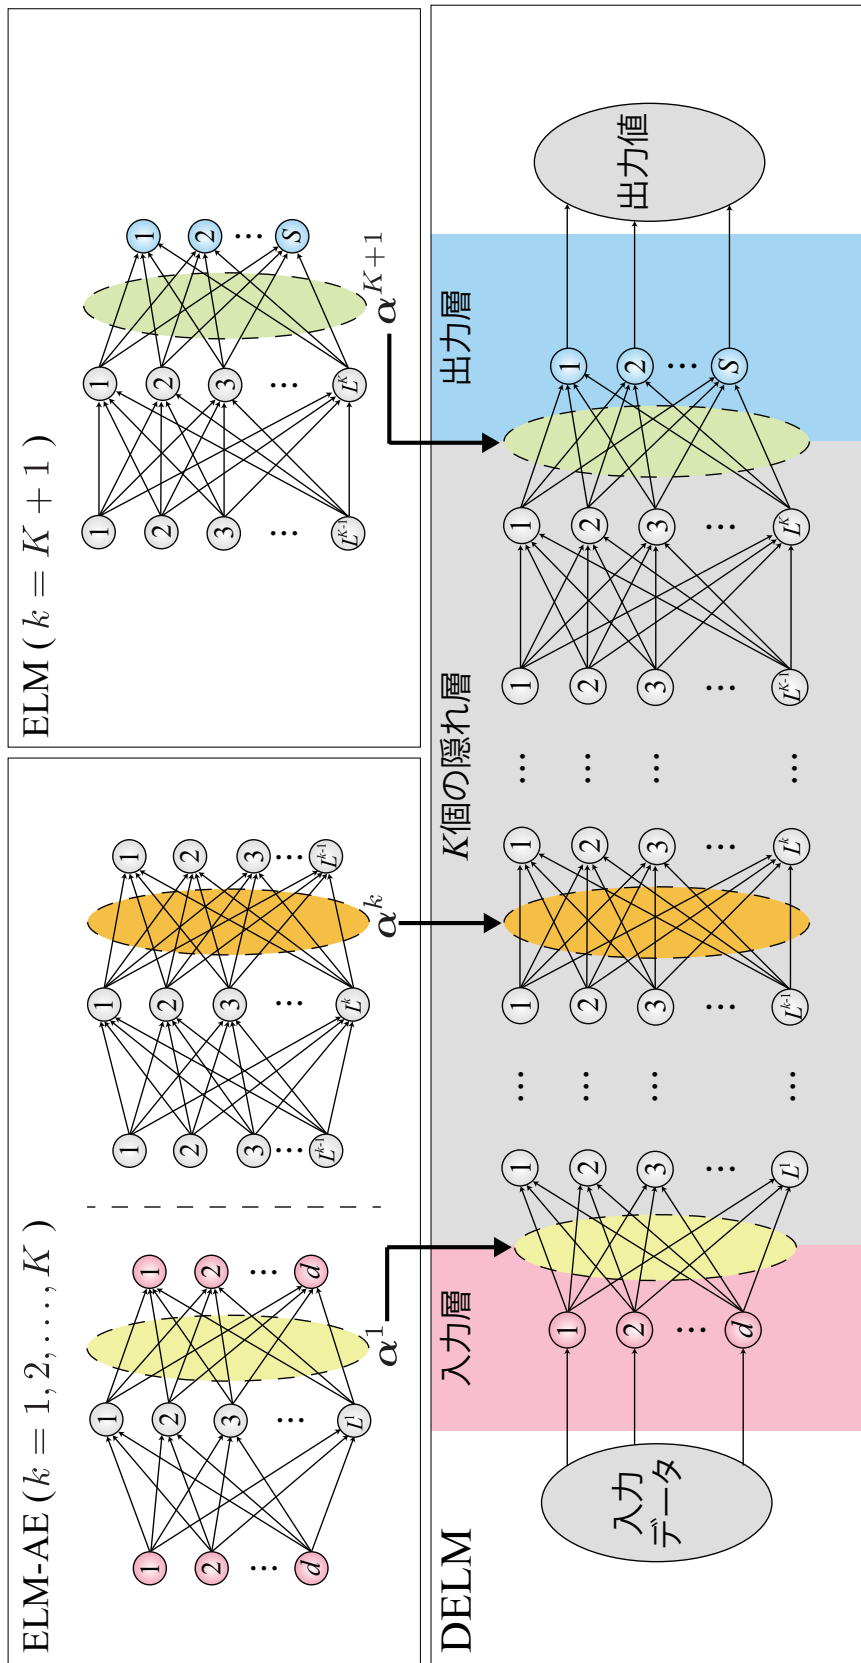


図 3.2: DELM の概要

(I) $k = 1, 2, \dots, K$ の場合

k 番目における隠れ層の出力 $\mathbf{H}^k = [\mathbf{h}_1^k, \mathbf{h}_2^k, \dots, \mathbf{h}_N^k]^T \in \mathbb{R}^{N \times L^k}$ と $(k-1)$ 番目における隠れ層の出力 $\mathbf{H}^{k-1} \in \mathbb{R}^{N \times L^{k-1}}$ との関係は、次式により得られる。

$$\mathbf{H}^k = g\left(\mathbf{H}^{k-1} (\boldsymbol{\alpha}^k)^T\right) \quad (3.11)$$

ここで、 $\boldsymbol{\alpha}^k \in \mathbb{R}^{L^k \times L^{k-1}}$ は k 番目の隠れ層および $(k-1)$ 番目の隠れ層間の重みを示し、 $g(\cdot)$ は活性化関数を示す。ただし、 L^k は $(k-1)$ 番目の隠れ層のノード数を示す。また、 $k-1=0$ は入力層を示し、 \mathbf{H}^0 は前節で得られた特徴ベクトル \mathbf{x}_i により与えられる。重み行列 $\boldsymbol{\alpha}^k$ を算出するために、本手法では各層に ELM-AE を構築する。ELM-AE では、入力ベクトル \mathbf{h}_i^{k-1} を与えたとき、出力 \mathbf{w}_i^k が下式のように算出される。

$$\mathbf{w}_i^k = g\left(\mathbf{A}^k \mathbf{h}_i^{k-1} + \mathbf{b}^k\right) \quad (3.12)$$

ここで、 $\mathbf{A}^k = [\mathbf{a}_1^k, \mathbf{a}_2^k, \dots, \mathbf{a}_{L^k}^k]^T \in \mathbb{R}^{L^k \times L^{k-1}}$ は直交する重み付きランダム行列を示し、 $\mathbf{b}^k = [b_1^k, b_2^k, \dots, b_{L^k}^k]^T \in \mathbb{R}^{L^k}$ は ELM-AE のランダムなバイアスを示す。重み行列 $\boldsymbol{\alpha}^k$ の算出は、ELM-AE の入力の行列 \mathbf{H}^{k-1} と各隠れ層の出力の行列 $\mathbf{W}^k = [\mathbf{w}_1^k, \mathbf{w}_2^k, \dots, \mathbf{w}_N^k]^T \in \mathbb{R}^{N \times L^k}$ を用いて以降の2つのパターンで算出される。

(I-A) $L^k \neq L^{k-1}$ の場合

第 k 層のノード数 L^k と第 $k-1$ 層のノード数 L^{k-1} が異なる場合は下式により $\boldsymbol{\alpha}^k$ が算出される。

$$\boldsymbol{\alpha}^k = \left(\frac{\mathbf{I}}{C_1} \sum_{l^k=1}^{L^k} \text{KL}(\rho \parallel \hat{\rho}_{l^k}) + (\mathbf{W}^k)^T \mathbf{W}^k \right)^{-1} (\mathbf{W}^k)^T \mathbf{H}^{k-1} \quad (3.13)$$

$$\text{KL}(\rho \parallel \hat{\rho}_{l^k}) = \rho \log \frac{\rho}{\hat{\rho}_{l^k}} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_{l^k}} \quad (3.14)$$

ここで, $\text{KL}(\rho \|\hat{\rho}_{l^k})$ は KL ダイバージェンス, ρ は平均活性度の目標値を示すパラメータ ($\rho = 0.05$), $\hat{\rho}_{l^k}$ は ELM-AE の各ノード l^k における活性度の平均である. また, \mathbf{I} は単位行列, C_1 は正規化パラメータである.

(I-B) $L^k = L^{k-1}$ の場合

L^k と L^{k-1} が等しい場合は, 以下に示す直交プロクラステス問題 [100] を解くことにより α^k を算出する.

$$\begin{aligned} \alpha^k &= \underset{\Omega}{\operatorname{argmin}} \|\Omega(\mathbf{H}^{k-1})^T - (\mathbf{W}^k)^T\|_F \\ &\text{subject to } \Omega^T \Omega = \mathbf{I} \end{aligned} \quad (3.15)$$

ここで, $\|\cdot\|_F$ はフロベニウスノルムを示す. 具体的に, 式 4.5 を文献 [101] に基づいて下式により特異値分解することで α^k を算出する.

$$\alpha^k = \mathbf{U}\mathbf{V}^T \quad (3.16)$$

$$(\mathbf{W}^k)^T \mathbf{H}^{k-1} = \mathbf{U}\mathbf{T}\mathbf{V}^T \quad (3.17)$$

ここで, $\mathbf{U} \in \mathbb{R}^{L^k \times L^k}$ および $\mathbf{V} \in \mathbb{R}^{L^{k-1} \times L^{k-1}}$ は直行行列であり, $\mathbf{T} \in \mathbb{R}^{L^k \times L^{k-1}}$ は特異値の行列, および $(\alpha^k)^T \alpha^k = \mathbf{I}$ である. 以上より, ELM-AE の隠れ層の出力行列 α^k を算出する.

(II) $k = K + 1$ の場合

第 K 層-出力層間の重み行列 α^{K+1} は ELM と同様に, 教師あり学習により算出する. 具体的に, α^k は下式によって算出される.

$$\alpha^k = \mathbf{T}\mathbf{H}^k \left(\frac{\mathbf{I}}{C_2} + \mathbf{H}^k (\mathbf{H}^k)^T \right)^{-1} \quad (3.18)$$

ここで, $\mathbf{T} = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N] \in \mathbb{R}^{S \times N}$ および $\mathbf{t}_n = [t_{i,1}, t_{i,2}, \dots, t_{i,S}]^T$ は教師ラベルを含む. また, C_2 は正規化パラメータを示している. 正解ラベル \mathbf{h}_i^k が s

($s = 1, 2, \dots, S$; S は基本戦術数) の場合は, $t_{i,s} = 1$ となり, 他の要素の値は 0 となる.

以上より, DELM の学習が行われる. テストフェーズでは, 新たな特徴ベクトル \mathbf{x}_i を DELM に入力することで各基本戦術の推定値 $v_i^{\text{Ret}}, v_i^{\text{FC}}, v_i^{\text{Poss}}, v_i^{\text{Sw}}$ を算出する. 最終的に, 下式に基づいて値が最大となる基本戦術を推定結果として取得する.

$$\text{label}_i = \arg \max_{q \in \{\text{Ret}, \text{FC}, \text{Poss}, \text{Sw}\}} v_i^q \quad (3.19)$$

以上の処理をサッカー映像のそれぞれのフレームに適用することで, 基本戦術が推定される.

3.4 実験

本章では, 提案した基本戦術の推定手法の有効性を確認するために実際のサッカー映像を用いて基本戦術を推定する実験を行う. 以降, まず 3.4.1 では, 実験条件として, データセット, 評価の方法および比較手法について説明する. 次に, 3.4.2 において, 実際のサッカー映像に提案した基本戦術の推定手法を適用することにより, 手法の有効性を示す.

3.4.1 実験条件

本実験では, サッカー映像 (4,611 秒, 5fps) を用いた. 具体的に, サッカー映像では, 表 3.3 に示す通り基本戦術の推定対象とするチーム A はリトリートを 1,541 秒, フォアチェックを 613 秒, ビルドアップを 2,045 秒, 速攻を 412 秒用いて競技を行った. 本実験では, 文献 [14, 20] の他手法と比較して, 多くの映像フレーム数で実験を行っている. Ground-truth (GT) は 10 年以上の経験がある 3 名のサッカー経験者により付与された. 提案手法で用いるパラメータは推定精度が最も高くなる時の値を採用した. 5 分割交差検定により検証を行い, 次式に示

再現率 (Recall), 適合率 (Precision), および F 値を用いて推定精度の評価を行った.

$$\text{再現率} = \frac{\text{推定結果と GT が一致したフレーム数}}{\text{実際に戦術が用いられたフレーム数}} \quad (3.20)$$

$$\text{適合率} = \frac{\text{推定結果と GT が一致したフレーム数}}{\text{推定手法より戦術を推定したフレーム数}} \quad (3.21)$$

$$\text{F 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad (3.22)$$

さらに, 比較手法として, 提案手法で用いる DELM を機械学習手法の一つである Support Vector Machine (SVM) [102] に置き換えた手法を用いて本手法の有効性を示す.

表 3.3: 実験で用いたデータの詳細

基本戦術	秒数
リトリート	1,541
フォアチェック	613
ビルドアップ	2,045
速攻	412
合計	4,611

提案手法で用いたパラメータの一覧を表 3.4 に示す. ただし, 提案および比較手法のパラメータは, それぞれの性能が最も高くなるように決定した.

表 3.4: 提案手法で用いたパラメータの詳細

詳細	パラメータ	値
入力ノード数	d	111
隠れ層の数	K	6
正規化に関するパラメータ	C_1	-2^{10}
	C_2	-2^{10}
隠れ層のノード数	L^1	131
	L^2	131
	L^3	171
	L^4	131
	L^5	111
	L^6	151
出力ノード数	S	4

3.4.2 実験結果

実験の結果を表 3.5 に示す。表 3.5 において、提案手法の全評価指標の平均が比較の精度を上回っていることが確認されたため、提案手法で用いた DELM の有効性が確認された。続いて、定性評価を行う。提案および比較手法を用いて基本戦術を推定した結果の一部を図 3.3 に示す。ただし、本実験では、図に示されるチーム A の基本戦術を推定している。図より、提案手法が比較よりも正しく基本戦術を推定可能としていることが確認でき、その結果が GT に最も近くなっている。具体的には、比較手法は正解がリトリートである区間をフォアチェックやビルドアップとして多く誤推定しているのに対して、提案手法は正しくリトリートを推定している。以上のことから、DELM により、基本戦術の推定精度を大幅に向上させることを可能とした。

表 3.5: 各手法の再現率 (Recall), 適合率 (Precision), および F 値

基本戦術	提案手法			比較手法		
	再現率	適合率	F 値	再現率	適合率	F 値
リトリート	0.888	0.853	0.870	0.847	0.860	0.853
フォアチェック	0.807	0.801	0.804	0.759	0.766	0.762
ビルドアップ	0.878	0.889	0.888	0.811	0.854	0.831
速攻	0.747	0.786	0.766	0.769	0.804	0.786
平均	0.830	0.835	0.832	0.797	0.821	0.808

3.5 まとめ

本章では、DELM に基づくことで少量の学習データにおいても高精度に基本戦術を推定することを可能とした。具体的に、提案手法では、選手位置データを用いてフォーメーション特徴量を算出した。次に、深層学習手法の DELM を用




図 3.3: 提案および比較手法によって得られた基本戦術の推定結果

いて基本戦術を推定した. 以上により, 少量の学習データにおいてもパラメータが最適化され, 従来の基本戦術の推定手法と比較して高精度化が実現された.

第4章 チームの戦術の関係性に基づく制約を導入したチーム戦術の推定

4.1 はじめに

本章では，チームの戦術の関係性に基づく制約を導入したサッカー映像における基本戦術を推定する手法について述べる．提案手法では，表 4.1 に示すチームの戦術の関係性とボールの保持率に着目して基本戦術の推定することで精度の向上を可能とする．図 4.1 に提案手法の概要を示す．まず，はじめに2チームそれぞれのフォーメーション特徴量を算出する．次に，得られたフォーメーション特徴量を用いて，前章において提案した DELM のパラメータを学習し，テストにおけるフォーメーション特徴量をそれぞれ構築した DELM に入力することで推定値を取得する．その後，競い合う2チームの両方が攻撃または守備の戦術にならないことに着目して，表 4.1 に基づき2チームの基本戦術の組み合わせを算出する．最後に，選手とボール位置より算出したボールの保持率からチームがボールを保持した区間を算出し，その区間に基づいて基本戦術の組み合わせの更新を行う．以上により，サッカーの戦術の関係性に基づいて基本戦術を推定することが可能となり，精度の向上が期待される．本章の最後では，実験により，チームの戦術の関係性を用いない手法や基本戦術を推定する等の最新手法との比較により，チームの戦術の関係性を用いて基本戦術を推定する手法の有効性の確認を行う．ただし，本章では，3.2 と同様に「リトリート」，「フォアチェック」，「ビルドアップ」，および「速攻」の4種類の基本戦術の推定に焦点を当てた．

以降，4.2 において，フォーメーション特徴量の算出について述べ，4.3 におい

て、DELMに基づく基本戦術の推定値を算出する方法について述べる。その後、4.4において、チームの戦術の関係性に基づいて基本戦術を補正する手法について述べ、4.5において、提案手法の有効性を検証するために、実際のサッカー映像に手法を適用し基本戦術を推定する実験を行う。

表 4.1: 2チームにおける戦術の関係性. Ret, FC, Set, Poss, Sw はそれぞれリトリート, フォアチェック, セットプレイ, ビルドアップ, 速攻を示す.

		チーム A				
		基本戦術	Ret	FC	Set	Poss
チーム B	Ret	-	-	-	✓	✓
	FC	-	-	-	✓	✓
	Set	-	-	✓	-	-
	Poss	✓	✓	-	-	-
	Sw	✓	✓	-	-	-

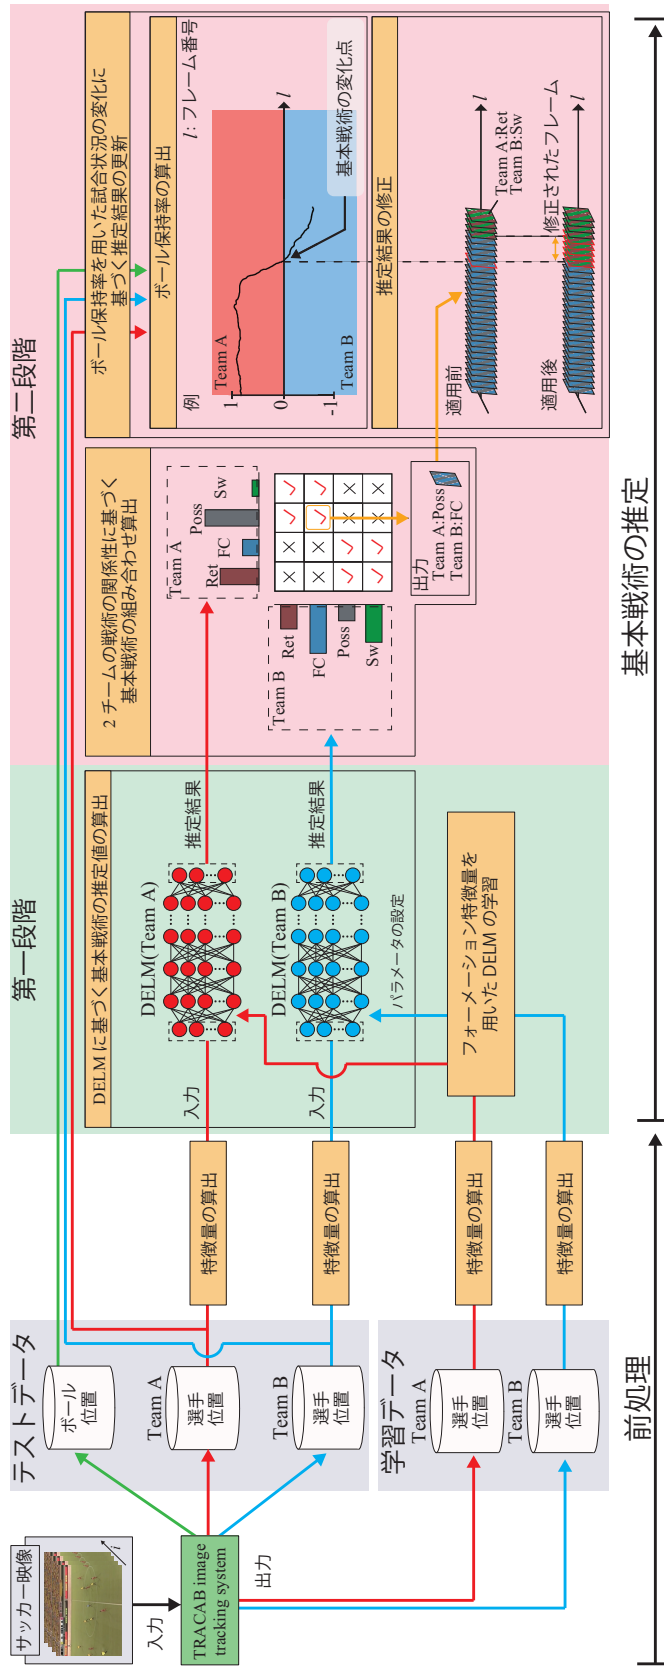


図 4.1: 提案手法の概要. 前処理として特徴量の算出を行う (4.2). 提案手法では, 2つの段階により構成されている. まず, 第一段階では, DELM に基づき基本戦術の推定値を算出する (4.3). 続いて, 第二段階では, チームの戦術の関係性とボール保持率に基づき基本戦術の推定結果を補正する (4.4).

4.2 前処理：フォーメーション特徴量の算出

本節では、TRACAB image tracking system¹により事前に取得した選手位置データを用いてフォーメーション特徴量を算出する。フォーメーション特徴量は選手間の距離や選手の速さ、加速度の大きさ、移動方向などの計 111 次元の特徴量により構成される。ただし、フォーメーション特徴量の算出は 3.2 と同様の手法で行われる。提案手法では、各チームの選手位置から特徴ベクトル $\mathbf{x}_i^j \in \mathbb{R}^{111}$ ($i = 1, 2, \dots, N; j \in \{\text{teamA}, \text{teamB}\}; N$ はサッカー映像の総フレーム数) をそれぞれのチームごとに算出する。

4.3 DELM に基づく基本戦術の推定値の算出

本節では、フォーメーション特徴量を用いて DELM によって基本戦術の推定値の算出方法について述べる。DELM は、1 層の入力層、 K 層の隠れ層、1 層の出力層の合計 $K + 2$ 層により構成されている。学習は第 k 層および第 $k - 1$ 層間の重み行列 (ただし、 $k = 1, 2, \dots, K + 1$) を逐次計算することより行われる。具体的に、(I) $k = 1, 2, \dots, K$ の重み行列 α_j^k は ELM-AE を各層ごとに構築することにより取得される。一方で、(II) $k = K + 1$ の重み行列 α_j^{K+1} は、ELM と同様に教師あり学習によって算出される。以降では、上記で述べたそれぞれの重み行列を算出する方法を説明する。

(I) $k = 1, 2, \dots, K$ の場合

k 番目における隠れ層の出力 $\mathbf{H}_j^k = [\mathbf{h}_{1,j}^k, \mathbf{h}_{2,j}^k, \dots, \mathbf{h}_{N,j}^k]^T \in \mathbb{R}^{N \times L^k}$ と $(k - 1)$ 番目における隠れ層の出力 $\mathbf{H}_j^{k-1} \in \mathbb{R}^{N \times L^{k-1}}$ との関係は、次式により得られる。

$$\mathbf{H}_j^k = g \left(\mathbf{H}_j^{k-1} (\alpha_j^k)^T \right) \quad (4.1)$$

ここで、 $\alpha_j^k \in \mathbb{R}^{L^k \times L^{k-1}}$ は k 番目の隠れ層および $(k - 1)$ 番目の隠れ層間の重みを示し、 $g(\cdot)$ は活性化関数を示す。ただし、 L^k は $(k - 1)$ 番目の隠れ層のノ-

¹<https://chyronhego.com/products/sports-tracking/>

ド数を示す. また, $k - 1 = 0$ は入力層を示し, \mathbf{H}_j^0 は前節で得られた特徴ベクトル $\mathbf{x}_{i,j}$ により与えられる. 重み行列 α_j^k の計算を行うために, 提案手法では, 各層に ELM-AE が構築される. ELM-AE は入力ベクトル $\mathbf{h}_{i,j}^{k-1}$ を与えたとき, 出力 $\mathbf{w}_{i,j}^k$ が下式のように算出される.

$$\mathbf{w}_{i,j}^k = g(\mathbf{A}^k \mathbf{h}_{i,j}^{k-1} + \mathbf{b}^k) \quad (4.2)$$

ここで, $\mathbf{A}^k = [\mathbf{a}_1^k, \mathbf{a}_2^k, \dots, \mathbf{a}_{L^k}^k]^\top \in \mathbb{R}^{L^k \times L^{k-1}}$ は直交する重み付きランダム行列を示し, $\mathbf{b}^k = [b_1^k, b_2^k, \dots, b_{L^k}^k]^\top \in \mathbb{R}^{L^k}$ は ELM-AE のランダムなバイアスを示す. 重み行列 α_j^k の算出は, ELM-AE の入力の行列 \mathbf{H}_j^{k-1} と各隠れ層の出力の行列 $\mathbf{W}_j^k = [\mathbf{w}_{j,1}^k, \mathbf{w}_{j,2}^k, \dots, \mathbf{w}_{j,N}^k]^\top \in \mathbb{R}^{N \times L^k}$ を用いて以降の2つのパターンで算出される.

(I-A) $L^k \neq L^{k-1}$ の場合

第 k 層のノード数 L^k と第 $k - 1$ 層のノード数 L^{k-1} が異なる場合は, α_j^k が下式のように算出される.

$$\alpha_j^k = \left(\frac{\mathbf{I}}{C_1} \sum_{l^k=1}^{L^k} \text{KL}(\rho \parallel \hat{\rho}_{l^k}) + (\mathbf{W}_j^k)^\top \mathbf{W}_j^k \right)^{-1} (\mathbf{W}_j^k)^\top \mathbf{H}_j^{k-1} \quad (4.3)$$

$$\text{KL}(\rho \parallel \hat{\rho}_{l^k}) = \rho \log \frac{\rho}{\hat{\rho}_{l^k}} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_{l^k}} \quad (4.4)$$

ここで, $\text{KL}(\rho \parallel \hat{\rho}_{l^k})$ は KL ダイバージェンス, ρ は平均活性度の目標値を示すパラメータ ($\rho = 0.05$), $\hat{\rho}_{l^k}$ は ELM-AE の各ノード l^k における活性度の平均である. また, \mathbf{I} は単位行列, C_1 は正規化パラメータである.

(I-B) $L^k = L^{k-1}$ の場合

L^k と L^{k-1} が等しい場合は, 以下に示す直交プロクラステス問題 [100] を解くことにより α_j^k が算出される.

$$\alpha_j^k = \underset{\Omega}{\operatorname{argmin}} \|\Omega (\mathbf{H}_j^{k-1})^\top - (\mathbf{W}_j^k)^\top\|_F$$

$$\text{subject to } \boldsymbol{\Omega}^T \boldsymbol{\Omega} = \boldsymbol{I} \quad (4.5)$$

ここで、 $\|\cdot\|_F$ はフロベニウスノルムを示す. 具体的に, 式4.5を文献 [101] に基づいて下式により特異値分解することで $\boldsymbol{\alpha}_j^k$ を算出する.

$$\boldsymbol{\alpha}_j^k = \boldsymbol{U}\boldsymbol{V}^T \quad (4.6)$$

$$(\boldsymbol{W}_j^k)^T \boldsymbol{H}_j^{k-1} = \boldsymbol{U}\boldsymbol{\Gamma}\boldsymbol{V}^T \quad (4.7)$$

ここで, $\boldsymbol{U} \in \mathbb{R}^{L^k \times L^k}$ および $\boldsymbol{V} \in \mathbb{R}^{L^{k-1} \times L^{k-1}}$ は直行行列であり, $\boldsymbol{\Gamma} \in \mathbb{R}^{L^k \times L^{k-1}}$ は特異値の行列, および $(\boldsymbol{\alpha}_j^k)^T \boldsymbol{\alpha}_j^k = \boldsymbol{I}$ である. 以上より, ELM-AE の隠れ層の出力行列 $\boldsymbol{\alpha}_j^k$ を算出する.

(II) $k = K + 1$ の場合

第 K 層および出力層間の重み $\boldsymbol{\alpha}_j^{K+1}$ は ELM と同様に, 教師あり学習により算出する. 具体的に, $\boldsymbol{\alpha}_j^k$ は次式によって算出される.

$$\boldsymbol{\alpha}_j^k = \boldsymbol{T}_j \boldsymbol{H}_j^k \left(\frac{\boldsymbol{I}}{C_2} + \boldsymbol{H}_j^k (\boldsymbol{H}_j^k)^T \right)^{-1} \quad (4.8)$$

ここで, $\boldsymbol{T}_j = [t_{j,1}, t_{j,2}, \dots, t_{j,N}] \in \mathbb{R}^{S \times N}$ および $t_{j,n} = [t_{i,j,1}, t_{i,j,2}, \dots, t_{i,j,S}]^T$ は教師ラベルを含む. また, C_2 は正規化パラメータを示している. 正解ラベル $\boldsymbol{h}_{i,j}^k$ が s ($s = 1, 2, \dots, S; S$ は基本戦術数) の場合は, $t_{i,j,s} = 1$ となり, 他の要素の値は0となる.

以上より, DELM の学習が行われる. テストフェーズにおいては, 新たな特徴ベクトル $\boldsymbol{x}_{i,j}$ を DELM へ入力することにより基本戦術の推定値 $v_{i,j}^{\text{Ret}}, v_{i,j}^{\text{FC}}, v_{i,j}^{\text{Poss}}, v_{i,j}^{\text{Sw}}$ が各チームで算出される.

4.4 チームの戦術の関係性に基づく基本戦術の推定結果の補正

本節では、サッカー競技における戦術の特徴を考慮することで基本戦術を更新する手法について述べる。本手法は、前節で得られた基本戦術の推定値に対して、以降で示す2つの処理を適用することにより、より正確な基本戦術の更新を試みる。具体的に、両チームの戦術の関係から基本戦術の組み合わせを算出し (4.4.1)、ボール保持率に基づく試合状況の変化により基本戦術を修正する (4.4.2)。1つ目の処理では、両チームの基本戦術の関係性が表 4.1 に示す8つのパターンに限定されることに着目して基本戦術の推定値からこれらの組み合わせを算出する。これにより、例えば、両チームの基本戦術が守備となるような誤った推定結果を防ぐことが可能となる。続いて、2つ目の処理は、試合状況における時間的変化がボールを保持しているチームの変化に基づいていることに着目して、この保持チームに基づき基本戦術の推定結果の修正を行う。以上により、基本戦術における時間的変化の正確な把握が可能となり推定の高精度化が実現される。以降では、上述した提案手法について述べる。

4.4.1 2チームの戦術の関係性に基づく基本戦術の組み合わせの算出

本手法では、2つのチームの戦術の関係性に基づいて、基本戦術の組み合わせが算出される。提案手法では、図 4.1 の第二段階における「セットプレイ」以外の組み合わせに対応する2チームの8種類の値 $z_c (c \in \text{Comb})$ を算出する。ただし、 $\text{Comb} = \{(\text{Ret}, \text{Poss}), (\text{Ret}, \text{Sw}), (\text{FC}, \text{Poss}), (\text{FC}, \text{Sw}), (\text{Poss}, \text{Ret}), (\text{Poss}, \text{FC}), (\text{Sw}, \text{Ret}), (\text{Sw}, \text{FC})\}$ である。 z_c の値は、DELM により得られた推定値を用いて表に対応する基本戦術の出力値を加算することで取得される。例えば、A チームが「リトリート」および B チームが「速攻」の場合は組み合わせが (Ret, Sw) となり、 $v_{i, \text{teamA}}^{\text{Ret}}$ に $v_{i, \text{teamB}}^{\text{Sw}}$ を加算することで $z_{(\text{Ret}, \text{Sw})}$ が算出される。最終的に、次式

によって基本戦術の最適な組み合わせを算出する.

$$\text{Label} = \arg \max_{c \in \text{Comb}} z_c \quad (4.9)$$

本手法では、瞬間的な誤推定を防ぐために基本戦術の組み合わせの結果に対し、投票処理を各フレームで適用する. 具体的には、対象フレームの前後の M フレームについて、式 (4.9) の推定結果に対して投票を行う. 以上により、表 4.1 に示す 2 チームの戦術の関係性に基づいた両チームの推定結果が取得される.

4.4.2 ボール保持率を用いた試合状況の変化に基づく推定結果の更新

ボール保持率による試合状況の変化に基づき推定結果を更新する方法について説明をする. 処理の概要を図 4.2 に示す. 本手法では、ボール保持チームに基づいて、チームに用いられる基本戦術が変化した点を推定し、その結果に基づき前節において得られた基本戦術推定の結果を更新する. 具体的にまず、ボールと選手の位置データを用いて、対象フレーム l のボール保持率 Ball_l を算出する. ボール保持率は片方のチームがボールを保持している度合いを示す. 続いて、ボール保持率が 0 を超えたとき、もしくは 0 を下回った場合のフレーム l を変化点とする. 最後に、変化点に基づいてその隣接するフレームの基本戦術推定の結果を修正することにより、最終的な推定結果を得る. 以降では、 Ball_l の算出について述べる.

Ball_l は、各対象フレームにおける選手のボール保持状況に基づいて算出される. 具体的に、文献 [103, 104] に基づき、ボール保持選手は以降に示す 4 つの条件を満たす.

条件 1:

ボールを持っている選手は、全選手の中で最もボールに近い.

条件 2:

最もボールに近い選手とボールとの距離が $r[\text{m}]$ 以内である.

条件 3:

$\|\mathbf{b}_l - \mathbf{b}_{l-1}\| < \text{Th}_{\min}$ もしくは $\|\mathbf{b}_l - \mathbf{b}_{l-1}\| > \text{Th}_{\max}$ を満たす.

条件 4:

$\frac{\mathbf{b}_l \cdot \mathbf{b}_{l-1}}{\|\mathbf{b}_l\| \|\mathbf{b}_{l-1}\|} < \text{Th}_a$ を満たす.

ただし, \mathbf{b}_l は, l 番目のフレームと $(l+1)$ 番目のフレーム間におけるボールの位置変化を表すベクトルである. また Th_{\min} , Th_{\max} , Th_a は閾値である.

以上の条件に基づいたボール保持選手の算出結果を用いて, 以下の Ball_l を算出する.

$$\text{Ball}_l = \frac{1}{T} \sum_{l'=l-T}^l f(l') \quad (4.10)$$

$$f(l') = \begin{cases} 1 & \text{if } B_{l'} = \text{teamA} \\ -1 & \text{Otherwise} \end{cases}, \quad (4.11)$$

ここで, $B_{l'}$ は, フレーム l' 内でのボール保持チームを示す. 以上により, サッカー競技におけるチームの戦術の関係性に基づき DELM によって戦術推定が実現される.

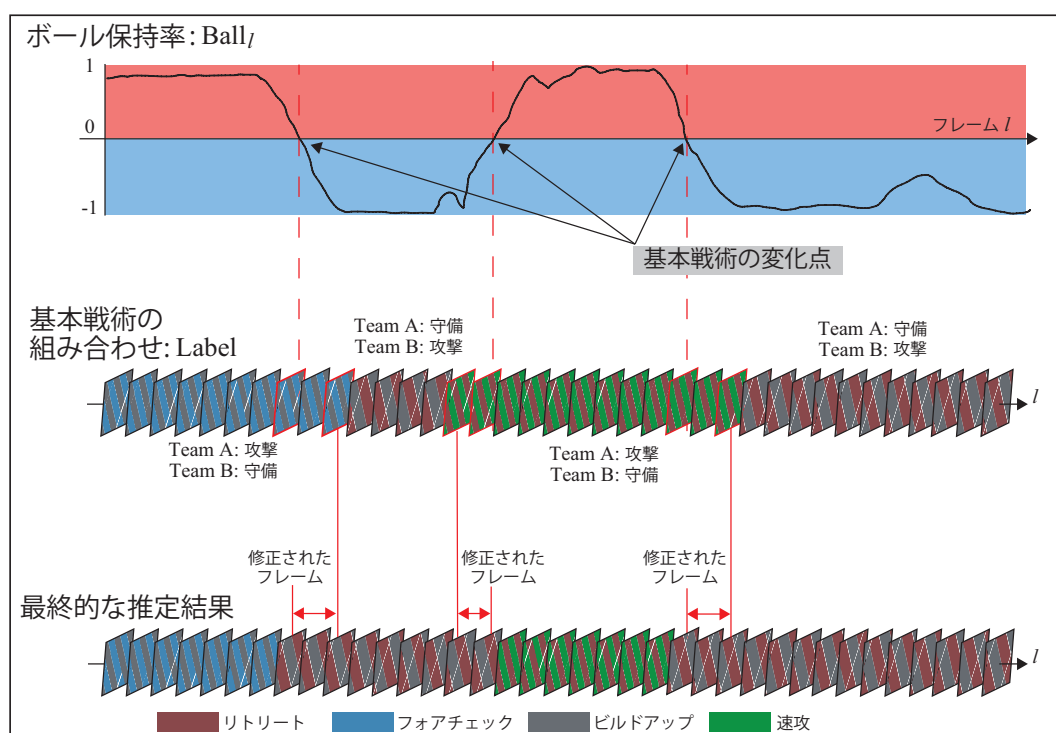


図 4.2: ボールの保持率に基づいた推定結果の更新方法

4.5 実験

本節では、提案した基本戦術の推定手法の有効性を確認するために実際のサッカー映像を用いて基本戦術を推定する実験を行う。4.5.1では、実験の条件を述べ、4.5.2では、実験の結果および考察について述べる。

4.5.1 実験条件

本実験では、サッカー映像（4,611秒、5fps）を用いてリトリート、フォアチェック、ビルドアップ、速攻の4つの戦術の推定を行う。表4.2において、用いるデータセットの概要が示されている。ここで、文献 [14, 20] 等の他手法と比較して、多くの映像フレーム数で実験を行っている。Ground-truth（GT）は10年以上の競技経験がある3名のサッカー経験者が付与した。5分割交差検定により検証を行い、次式に示す再現率（Recall）、適合率（Precision）、およびF値を用いて推定精度の評価を行った。

$$\text{再現率} = \frac{\text{推定結果と GT が一致したフレーム数}}{\text{実際に戦術が用いられたフレーム数}} \quad (4.12)$$

$$\text{適合率} = \frac{\text{推定結果と GT が一致したフレーム数}}{\text{推定手法より戦術を推定したフレーム数}} \quad (4.13)$$

$$\text{F 値} = \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \quad (4.14)$$

以降に示す10つの比較手法（比較手法1 - 比較手法10）を用いることで提案手法の有効性を定量的かつ定性的に示す。

- 比較手法1は基本戦術推定の最新手法である [96]。具体的に、フォーメーション特徴量を用いて Multiple Kernel Fuzzy C-Means (MKFC) [91] に基づき推定をする。
- 比較手法2は基本戦術推定の最新手法である [105]。具体的に、フォーメーション特徴量と映像特徴の両方を用いて SVM [102] により基本戦術を推定し、その結果を Decision Level Fusion [106] に基づき統合する。

- 比較手法3は、比較手法1のMKFCをRandom Forest [107]に置き換えた推定方法である。
- 比較手法4は、比較手法1のMKFCをK-Nearest Neighbor (K-NN) アルゴリズム [92]に置き換えた推定方法である。
- 比較手法5では、提案手法と同じフレームワークで異なる特徴量を用いている。具体的には、提案手法のフォーメーション特徴量を選手位置データに置き換えた手法である。
- 比較手法6は、提案手法のDELMをSVMに置き換えた推定手法である。
- 比較手法7は、提案手法のDELMを比較手法5と同様にELM [95]に置き換えた推定手法である。
- 比較手法8は、提案手法の第二段階を適用せずに、第一段階のみによる推定が行われる。
- 比較手法9では、CNNに基づいたベンチマーク手法の一つであるVGG16モデル [32]のファインチューニングにより基本戦術を推定している。
- 比較手法10では、CNNに基づいたベンチマーク手法の一つであるInception-V3モデル [108]のファインチューニングにより基本戦術を推定している。

比較手法の妥当性を以下に示す。

提案手法 vs 比較手法1および比較手法2

提案手法が基本戦術推定の最新手法と比較して有効となることの検証を行う。

提案手法 vs 比較手法3および比較手法4

提案手法が従来の機械学習に基づいた推定手法よりも有効となることの検証を行う。

提案手法 vs 比較手法5

フォーメーション特徴量の有効性を示す。

表 4.2: 実験で用いたデータの詳細

基本戦術	秒数
リトリート	1,541
フォアチェック	613
ビルドアップ	2,045
速攻	412
合計	4,611

提案手法 vs 比較手法 6 および比較手法 7

DELM の有効性を示す.

提案手法 vs 比較手法 8

チームの戦術の関係性に基づく推定結果の補正の有効性を示す.

提案手法 vs 比較手法 9 および比較手法 10

提案手法が CNN に基づいた基本戦術の推定手法よりも有効となることの検証を行う.

表 4.3 には, 提案手法で使用したパラメータの詳細が示されている. ただし, 各手法のパラメータは, それぞれの推定手法の精度が最大になるように決定した. 比較手法 9 と比較手法 10 では, 推定精度の公平な比較のために, Tensorflow [109] において実装が行われている, VGG16 モデルと Inception-V3 モデルを用いた. また, 誤差が 0.2 以上になるまで最大 50 エポックで学習を行った. 加えて, 検証用のデータセットの推定精度に基づいて, 最適なネットワークを選択した.

表 4.3: 提案手法で用いたパラメータの詳細

詳細	パラメータ	値
入力ノード数	d	111
隠れ層の数	K	6
正規化に関するパラメータ	C_1	-2^{10}
	C_2	-2^{10}
隠れ層のノード数 (Team A)	L^1	131
	L^2	131
	L^3	171
	L^4	131
	L^5	111
	L^6	151
隠れ層のノード数 (Team B)	L^1	131
	L^2	111
	L^3	171
	L^4	171
	L^5	111
	L^6	151
出力ノード数	S	4
投票処理のフレームサイズ	M	21
ボール保持率に関するパラメータ	r	2.0
	Th_{\min}	0.3
	Th_{\max}	1.2
	Th_a	$\cos\frac{\pi}{6}$
	T	15

表 4.4: 提案および比較手法 8 を 50 試行した際の平均と分散

手法	平均	分散
提案手法	0.865	9.62×10^{-4}
比較手法 8	0.816	9.09×10^{-4}

4.5.2 実験結果

表 4.5 では、全手法の定量評価を行った結果が示されている。これらより、提案手法が他手法よりも最も優れていることが示された。具体的には、基本戦術推定の最新手法が従来の機械学習に基づく手法（比較手法 1～比較手法 4）と比較しても高い精度となっていることが示されている次に、提案手法と比較手法 5 を比べることで、フォーメーション特徴量の有効性が示された。さらに、提案手法と比較手法 6、および比較手法 7 との比較により、DELM を使用することの有効性が示されている。また、提案手法の推定精度が比較手法 8 と比較して高くなっていることから、推定結果の補正の有効性が示された。最後に、提案手法と、比較手法 9 および比較手法 10 の結果を比較することで、本手法が隠れ層数が非常に多い CNN ネットワークを含む深層学習に基づいた手法よりも優れていることが示された。この結果から、CNN に基づいた手法は学習に用いるデータ量が少ない場合には不向きであることが示されている。加えて、DELM が SVM と比較して性能が良くなることが DELM の文献にて報告されており [39]、本実験においても同様の傾向となることが確認できる。さらに、提案した基本戦術の推定手法の統計的有意差を確認するために、提案手法および比較手法 8 においてウェルチの t 検定 [110] による有意差検証を行った。表 4.4 に各手法を 50 試行した時の平均と分散を示す。有意差検証より P 値が 0.01 以下となり、1% で優位であることが確認された。

表 4.5: 提案および比較手法における基本戦術推定の精度. R, P, F はそれぞれ再現率 (Recall), 適合率 (Precision), および F 値を示している.

基本戦術	提案手法			比較手法 1			比較手法 2		
	R	P	F	R	P	F	R	P	F
リトリート	0.928	0.917	0.923	0.780	0.394	0.523	0.683	0.670	0.676
フォアチェック	0.871	0.830	0.850	0.408	0.658	0.504	0.611	0.651	0.630
ビルドアップ	0.928	0.945	0.936	0.653	0.471	0.547	0.699	0.720	0.709
速攻	0.791	0.812	0.801	0.112	0.565	0.187	0.637	0.644	0.640
平均	0.880	0.876	0.878	0.488	0.522	0.440	0.658	0.671	0.664

基本戦術	比較手法 3			比較手法 4			比較手法 5		
	R	P	F	R	P	F	R	P	F
リトリート	0.657	0.672	0.665	0.600	0.616	0.608	0.877	0.825	0.850
フォアチェック	0.660	0.628	0.644	0.605	0.581	0.593	0.633	0.779	0.699
ビルドアップ	0.671	0.672	0.671	0.617	0.612	0.615	0.881	0.827	0.854
速攻	0.664	0.647	0.656	0.610	0.592	0.601	0.643	0.752	0.693
平均	0.663	0.655	0.669	0.608	0.600	0.604	0.759	0.796	0.774

基本戦術	比較手法 6			比較手法 7			比較手法 8		
	R	P	F	R	P	F	R	P	F
リトリート	0.878	0.860	0.869	0.856	0.837	0.847	0.888	0.853	0.870
フォアチェック	0.776	0.766	0.771	0.805	0.755	0.779	0.807	0.801	0.804
ビルドアップ	0.822	0.854	0.838	0.868	0.894	0.881	0.878	0.899	0.888
速攻	0.789	0.804	0.796	0.676	0.843	0.751	0.747	0.786	0.766
平均	0.816	0.821	0.818	0.802	0.832	0.814	0.830	0.835	0.832

基本戦術	比較手法 9			比較手法 10		
	R	P	F	R	P	F
リトリート	0.790	0.835	0.812	0.697	0.873	0.775
フォアチェック	0.771	0.683	0.724	0.880	0.427	0.575
ビルドアップ	0.819	0.831	0.825	0.695	0.876	0.775
速攻	0.807	0.638	0.713	0.692	0.860	0.767
平均	0.797	0.747	0.768	0.741	0.759	0.723

続いて、定性評価を行う。図 4.3 では、提案および比較手法による推定結果の一部が示されている。図 4.3 により、提案が最も精度良く推定可能としていることが示され、その結果は GT に最も近くなっていることが示されている。具体的に、比較手法 8 は推定される戦術が両チームで同じになることに対して、提案はチーム戦術を関係性に基づいて両チームの戦術を矛盾なく推定可能としている。以上より、チームの基本戦術の関係を用いることで、推定の精度が向上することが示された。

さらに、表 4.6 と表 4.7 に提案と比較手法 8 の推定結果の混同行列が示されている。この表から、推定結果の補正を導入することで、推定の精度が向上することが示されている。具体的には、「リトリート」と「ビルドアップ」を正しく推定することを可能とする。一般的に、これらの基本戦術はフォーメーションが類似している。提案では、ボール保持率に基づくことで、これらの基本戦術の推定結果を正しく更新することが可能となった。以上より、提案手法の新規性が基本戦術の高精度な推定に大きく寄与したことが示された。

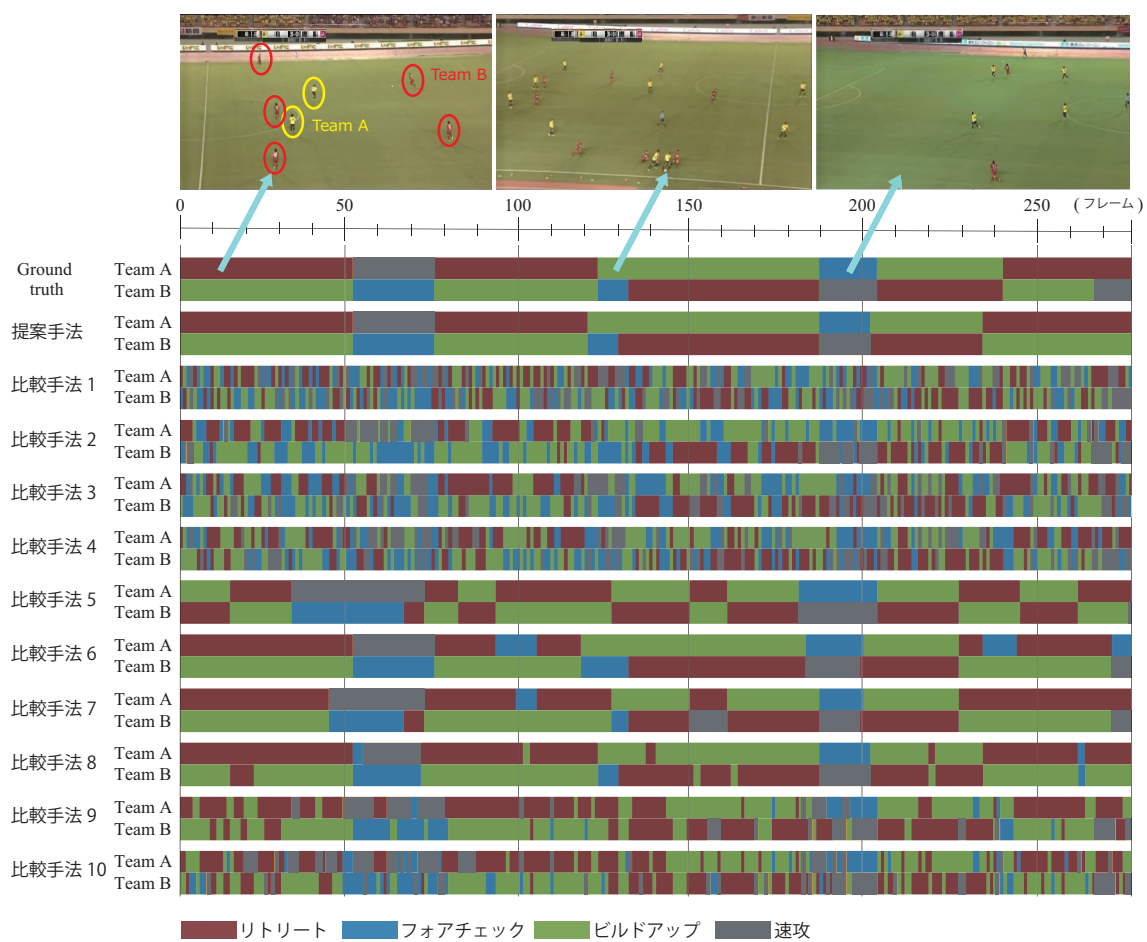


図 4.3: 提案および比較手法における基本戦術の推定結果

表 4.6: 提案手法における基本戦術の最適な組み合わせに基づく補正を適用する前の推定結果から得られた混同行列. これらの結果は, 比較手法 8 と対応する. Gt は Ground-truth を表す.

		推定結果			
		Ret	FC	Poss	Sw
Gt	Ret	1,396	48	110	19
	FC	31	510	39	52
	Poss	152	67	1,720	20
	Sw	57	12	44	334

表 4.7: 提案手法における基本戦術の最適な組み合わせに基づく補正を適用した後の推定結果から得られた混同行列. これらの結果は, 提案の結果と一致する. Gt は Ground-truth を表す.

		推定結果			
		Ret	FC	Poss	Sw
Gt	Ret	1,425	43	50	17
	FC	9	527	22	47
	Poss	80	54	1,897	14
	Sw	40	11	38	337

4.6 まとめ

本章では、チームの戦術の関係性に基づいた制約の導入により、高い精度で基本戦術の推定を可能とした。本手法では、フォーメーション特徴量により学習された DELM により各チームの基本戦術の推定値を算出し、チームの戦術の関係性に基づいた制約を導入して戦術の推定結果を補正した。これにより、対戦する2チームの戦術の組み合わせに基づく最適な補正が行われ、基本戦術推定の高精度化が達成された。

第5章 サッカー映像視聴時の経験者の視線データを用いた戦術解析

5.1 はじめに

本章では、サッカー競技に関する専門知識を導入することの有効性を示すために、サッカー経験者より取得した映像視聴時における視線データを用いた戦術解析手法を構築する。具体的に、選手位置データとサッカー映像視聴時における視線データに基づいた選手のネットワーク（以降、選手ネットワーク）を生成し、そのネットワークの解析により選手の重要度を推定する手法を提案する。重要度はパスによる他の選手との連携の度合いを示す指標である。例えば、重要度が高い選手は他の選手よりもパスを受ける可能性が高いなど、重要度推定によってチーム戦術において、重要な役割を果たす選手の抽出を可能とする。提案手法では、競技の知識を導入し、その知識に基づいた深層学習手法の構築により、少量の学習データからの戦術解析を可能とする。本手法では、2つの段階により実現しその概要が図5.1に示されている。まず、第一段階では、経験者の視線追跡データを用いて学習した注視位置の推定モデルと選手位置に基づき選手ネットワークを生成する。このとき、各選手が最も早く到達可能な領域（先着領域）[111]を選手位置から算出し、先着領域の隣接関係に基づいて選手をノードとする選手ネットワークを生成する。また、注視位置の推定モデルは経験者の視聴時の視線データを Long Short-Term Memory (LSTM) [112]によって学習し構築する。これにより、ボール保持選手と推定された注視位置に近い選手間にネットワークを生成する。第二段階では、生成した選手ネットワークに対して、HITS アルゴリズム

(Hypertext Induced Topic Selection) [113] を適用することで、各選手の重要度が推定される。以上により、サッカー経験者の注視位置が未知であるサッカー映像のフレームに対しても、経験者の専門知識に基づいた選手ネットワークを生成可能とし選手の重要度推定が実現される。

以降、**5.2**で、選手ネットワークの生成手法について述べし、**5.3**において、HITS アルゴリズムに基づいた選手の重要度の推定手法について述べる。その後、**5.4**では、実験条件および結果について述べ、最後に**5.5**で、まとめを行う。

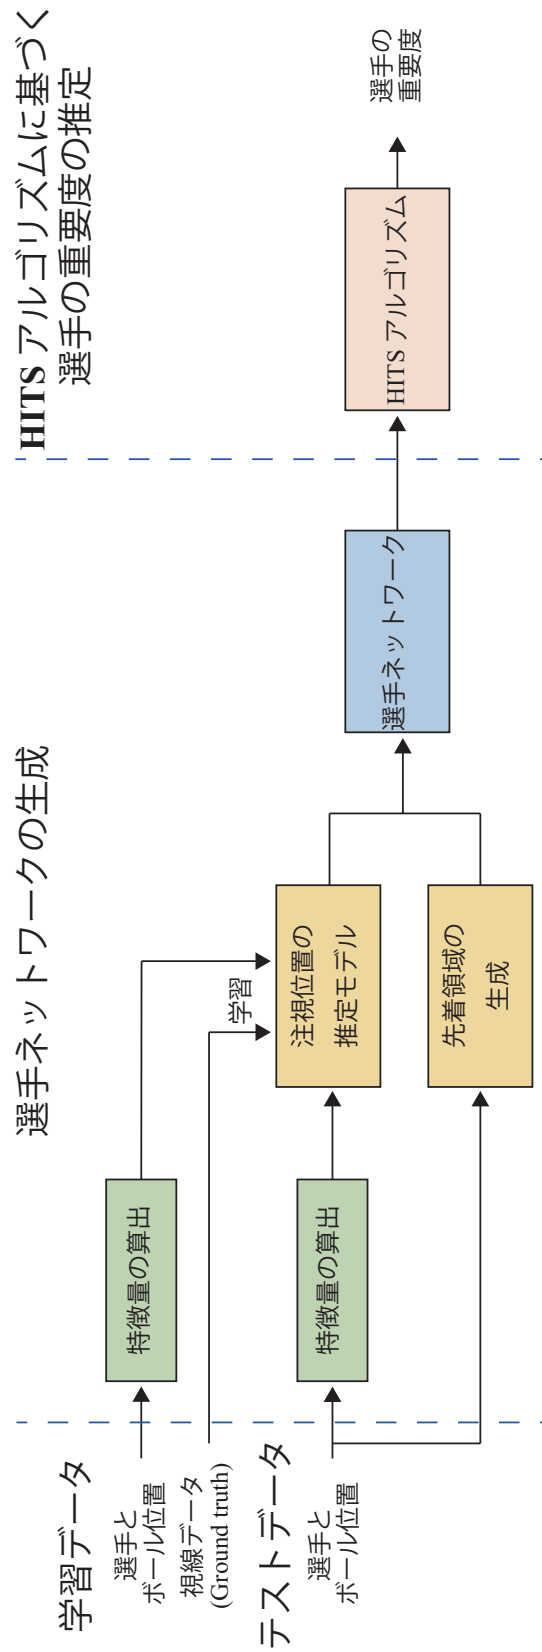


図 5.1: 提案手法の概要. 提案手法では, 2つの段階から構成される. まず, 第一段階では, 先着領域 (5.2.1) と注視位置推定モデル (5.2.2) に基づく選手ネットワーク (5.2) を生成する. 続いて, 第二段階では, HITS アルゴリズムを用いた重要度の推定 (5.3) を行う.

5.2 選手ネットワークの生成

本章では、選手ネットワークを生成する手法に関する説明をする．具体的に、サッカーフィールド上の攻撃チームの選手を p_t^m および p_t^n ($m, n = 1, 2, \dots, 11; m \neq n | t = 1, 2, \dots, T; T$ は総フレーム数) としたとき、選手ネットワークは次式で定義される選手同士の隣接行列 $\mathbf{L}_t = [L_t^{mn}]$ により表す．

$$[L_t^{mn}] = \begin{cases} \alpha \frac{l_t^{mn}}{d_t^{mn}} + (1 - \alpha)w_t^{mn} & (m \neq n) \\ 0 & (\text{otherwise}) \end{cases} \quad (5.1)$$

ここで、 l_t^{mn} は先着領域における選手 p_t^m と選手 p_t^n 間の境界辺の長さを示し、 d_t^{mn} は選手間の距離を示す． w_t^{mn} は推定された注視位置に基づくエッジ重みを示し、 $\alpha (0 \leq \alpha \leq 1)$ は調整を行うパラメータを示している．式 (5.1) における右辺では、第一項目が先着領域に基づいたエッジ重みを示し、第二項目が推定された注視位置に基づいたエッジ重みを示している．

以降では、先着領域および推定された注視位置に基づいてエッジ重みを算出する手法について、それぞれ述べる．

5.2.1 先着領域に基づくエッジ重みの算出

本節では、先着領域に基づいた選手ネットワークにおけるエッジ重みの算出方法について述べる．先着領域は、各選手がピッチに最初に到着する領域として定義される [111]．先着領域は各選手の色と位置から、フィールド上の任意の地点への最短到着時間により計算される．先着領域を生成するための選手 p_t^m の運動モデルは、以下に示す通り定義される．

$$m_{\text{player}} \frac{d}{ds} \mathbf{v}^m = \mathbf{F} - k\mathbf{v}^m \quad (5.2)$$

ここで、 m_{player} は選手の質量、 $\frac{d}{ds} \mathbf{v}^m$ は選手の速度 \mathbf{v}^m の時間 s の微分、 \mathbf{F} は選手の最大推進力のベクトル、 k は抗力定数である．さらに、 \mathbf{F} は $F\mathbf{e}$ であり、 F は

最大推進力, e は単位ベクトルである. ただし, 右辺の第二項目は, 時間とともに速度が無限にならないように, 文献 [114] に基づいた選手の動きに対する抵抗力を示している. 続いて, 式 (5.2) は次式に示すように書き換えられる.

$$\mathbf{x}^m - \mathbf{x}_t^m = V_{\max} \left(s - \frac{1 - e^{-\beta s}}{\beta} \right) + \frac{1 - e^{-\beta s}}{\beta} \mathbf{v}_t^m \quad (5.3)$$

ここで, 上式は, 式 (5.2) の微分方程式の解であり, \mathbf{x}^m は選手の位置, \mathbf{x}_t^m は p_t^m の現在位置, V_{\max} は選手の最大速度, \mathbf{v}_t^m は p_t^m の現在速度である. さらに, β は抵抗の大きさを表す. 式 (5.2) より, $\mathbf{v}^m < \frac{F}{k}$ が満たされるため, 式 (5.3) では, 速度 \mathbf{v}_t^m で \mathbf{x}_t^m にいる選手が, 時間長 s で点 \mathbf{x}^m に到達できることを示している. 最終的に, 選手 p_t^m が他の選手よりも早く到着できる先着領域 D は, 下式によって算出される.

$$D(p_t^m) = \{ \mathbf{x}^{\text{pnt}} \in \mathbf{R}^2 \mid t_s(\mathbf{x}^{\text{pnt}}, p_t^m) \leq t_s(\mathbf{x}^{\text{pnt}}, p_t^n), m \neq n \} \quad (5.4)$$

ここで, $t_s(\mathbf{x}^{\text{pnt}}, p_t^m)$ は, 選手 p_t^m が任意の位置 \mathbf{x}^{pnt} に到着するまでの最短時間を示す. 一般に, 同じチームに属する2人の選手の先着領域が隣接する際には, パスが成功となる能性が高くなる. したがって, 先着領域の境界線が長く, かつ, 2人の選手間の距離が小さい場合には, パスが成功となる可能性が高くなる. そこで, 提案手法では, 先着領域によって算出される l_t^{mn} および d_t^{mn} を用いて, 選手ネットワークのエッジ重みの算出により, 選手ネットワークが生成される. 図 5.2 に先着領域と l_t^{mn} と d_t^{mn} の例を示す. ただし, 青点と赤点はそれぞれ攻撃チーム選手と守備チーム選手に対応しており, 黒点はボールを示している. 黒線で囲まれた領域が先着領域となる.

提案手法では, 少ないパス回数で得点をするための戦術を用いる際に重要となる選手の推定に着目した. そのため, 先着領域による選手ネットワークを生成では, バックパスを考慮しない. したがって, 選手 p_t^n が選手 p_t^m の後ろに存在する場合, この二人の選手間でのパスの可能性は低くなる. この場合は, $[L_t^{mn}]$ は




図 5.2: 先着領域の例

0である。ただし、パスの受け手および出し手の候補者との関係が、推定された注視位置に基づいた選手ネットワークにより表現される場合があるため、クロスボール [1] によるバックパスを考慮することも可能となっている以降では、これらの詳細を以下に示す。

5.2.2 推定された注視位置に基づくエッジ重みの算出

本節では、注視位置の推定モデルに基づいた選手ネットワークのエッジ重みの算出方法を説明する。一般的にサッカー経験者がサッカー映像を視聴する際は、サッカーの戦術に注目する。具体的には、サッカー経験者は、戦術と密接に関係している選手の動きや位置、スペースなどを、未経験者よりも注目していることが述べられている [40,41]。このため、経験者の視線データはパスの受け手および出し手の関係を決定させるのに有効であると考えられる。そこで提案手法では、経験者の注視位置を正解データとし、選手・ボール位置データから算出した特徴量により、深層学習に基づいた注視位置を推定するモデルのパラメータを学習

表 5.1: 特徴量と Ground-truth の詳細

特徴量 : u_t	次元数
選手位置	44
ボール位置	2
フォーメーション特徴量 [96]	111
Ground-truth : d_t	
視線データからの注視位置	2

する。表 5.1 に正解データと特徴量の詳細が示されている。提案する推定モデルの構築により、経験者が未視聴のサッカー映像に対しても注視位置の推定が実現される。提案手法では、特徴量を推定モデルに入力して得られた注視位置を用いて、選手ネットワークにおけるパスの出し手および受け手との間のエッジ重みが算出される。以上により、経験者の戦術に関する知識を考慮した選手ネットワークの生成が実現される。

以降では、まず特徴量を算出する方法について述べる。その後、LSTM に基づいた注視位置の推定モデルを構築する手法について述べる。最後に、推定された注視位置に基づいた選手ネットワークの生成について述べる。

A. 注視位置と特徴量の算出

まず、表 5.1 に示すように、選手・ボール位置から特徴量 $u_t \in \mathbb{R}^{(44+2+111)}$ を抽出する。続いて、視聴時の S 人の経験者から視線データ $d_t \in \mathbb{R}^2$ を得る。提案手法では、得た特徴量と Ground-truth から、注視位置の推定モデルを学習する。ただし、経験者の注視位置は、文献 [115] に基づいて、サッカー映像のスクリーン座標系から選手・ボール位置データと同じ座標系に変換している。

B. LSTM に基づく注視位置の推定モデルの構築

近年、再帰型ニューラルネットワーク (RNN) は、映像認識、自然言語処理、音声認識など多くの系列データの学習において高い精度となることが示されている [82, 116, 117]. RNN は系列データのパターン認識に関する深層学習のモデルで

あり、ネットワーク内部に閉路を持つことで一時的に情報を記憶することを可能とする。このため、系列データの学習が可能となる。視線データは系列データであるため、本手法では、サッカー映像における注視位置の推定モデルをRNNを用いて構築する。具体的に、RNNの一つであるLSTM [112]を用いて注視位置を推定する。図5.3にLSTMのネットワーク構成が示されている。LSTMは入力判断ゲート i_t 、出力判断ゲート o_t 、忘却判断ゲート f_t 、およびメモリセル c_t により構成される。具体的に、下式によりそれぞれ算出される。

$$i_t = \sigma(\mathbf{Z}_{ui}\mathbf{u}_t + \mathbf{Z}_{hi}\mathbf{h}_{t-1} + \mathbf{Z}_{ci}\mathbf{c}_{t-1} + \mathbf{b}_i) \quad (5.5)$$

$$f_t = \sigma(\mathbf{Z}_{uf}\mathbf{u}_t + \mathbf{Z}_{hf}\mathbf{h}_{t-1} + \mathbf{Z}_{cf}\mathbf{c}_{t-1} + \mathbf{b}_f) \quad (5.6)$$

$$c_t = f_t\mathbf{c}_{t-1} + i_t \tanh(\mathbf{Z}_{uc}\mathbf{u}_t + \mathbf{Z}_{hc}\mathbf{h}_{t-1} + \mathbf{b}_c) \quad (5.7)$$

$$o_t = \sigma(\mathbf{Z}_{uo}\mathbf{u}_t + \mathbf{Z}_{ho}\mathbf{h}_{t-1} + \mathbf{Z}_{co}\mathbf{c}_t + \mathbf{b}_o) \quad (5.8)$$

$$\mathbf{h}_t = o_t \tanh(\mathbf{c}_t) \quad (5.9)$$

ここで、 \mathbf{u}_t および \mathbf{h}_t はそれぞれ入力ベクトルと出力ベクトルを示し、 i_t, f_t, c_t, o_t は各ゲートの出力を示す。 $\mathbf{Z}_{..}$ は各ゲート間の重み行列である。例えば、 \mathbf{Z}_{ui} は入力 \mathbf{u}_t と入力判断ゲート i_t 間の重み行列を示す。加えて、 \mathbf{b}_\bullet はバイアス重み、 $\sigma(\cdot)$ はシグモイド関数を示す。提案手法では、特徴量と視線データにより2次元の回帰を実行することで、注視位置推定のモデルを学習する。以下に示す平均二乗誤差 (MSE) [118] に基づいてコスト関数 C を設定する。

$$C = \frac{1}{T} \sum_{t=1}^T \|\mathbf{h}_t - \mathbf{d}_t\|^2. \quad (5.10)$$

本手法では、各ゲート間の重みを Backpropagation Through Time [119] に基づいて学習する。以上により、LSTM に基づいた注視位置の推定モデルを学習する。

テストフェーズでは、上記で構築したモデルに新たな特徴量 \mathbf{u}_t を入力することにより、LSTM の出力層から対象フレームに対応する注視位置の推定結果 \mathbf{u}_t が

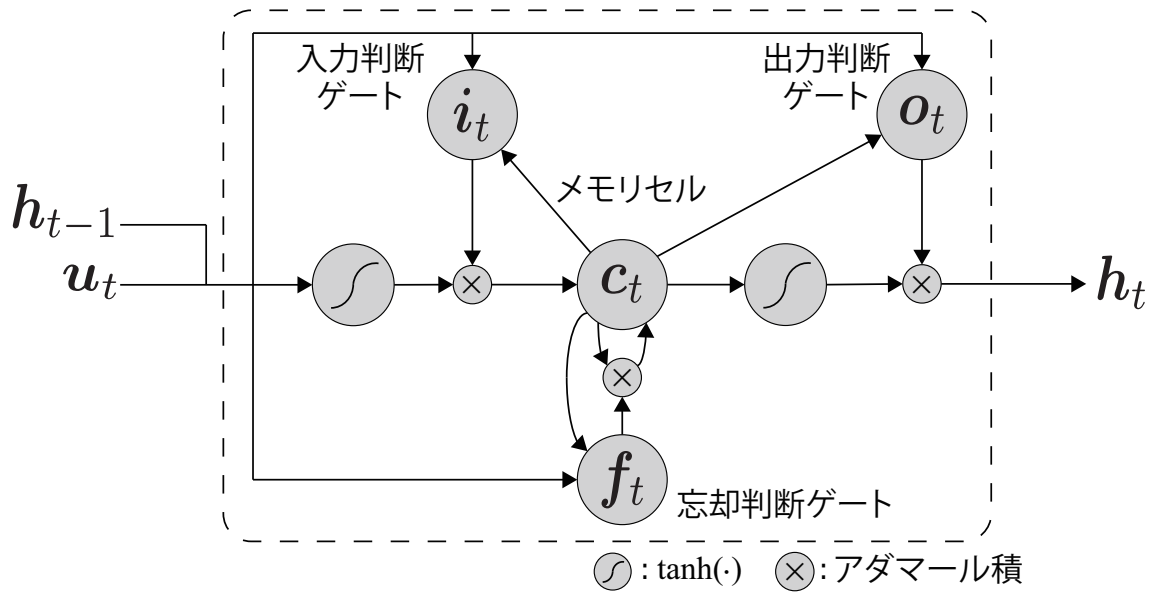


図 5.3: LSTM のネットワーク構造

式 5.9 により算出される。加えて、瞬間的な誤差の補正のために、推定された注視位置結果する投票処理を適用する。具体的には、対象フレームの前後の M フレームに対して投票処理を行う。これにより最も頻度が高い位置が注視位置の推定結果となる。

C. 注視位置に基づく選手ネットワークの生成

推定された注視位置を用いてエッジの強さ w_t^{mn} を算出する手法について述べる。ここで、経験者と未経験者の視覚能力に違いがあることが文献 [120] において述べられている。具体的に、経験者は未経験者に比べて周辺視野の動きの知覚範囲が広いことが示されている。本手法では、この周辺視野を考慮するために、注視位置と注視位置周辺に位置する各選手との距離に基づいて、複数の選手に対してネットワークを生成する。具体的に、過去の T' フレームに基づいて推定された注視位置 h_t を用いて、エッジ重み w_t^{mn} を次式に示すように算出する。

$$w_t^{mn} = \frac{1}{T'} \sum_{j=0}^{T'} z_{t-j}^{mn} \tag{5.11}$$

$$z_{t-j}^{mn} = \frac{\gamma_{t-j}^{mn}}{\text{dis}(\mathbf{h}_{t-j}, \mathbf{x}_{t-j}^n)} \quad (0 < \text{dis}(\mathbf{h}_{t-j}, \mathbf{x}_{t-j}^n) \leq R) \quad (5.12)$$

ここで、 $\text{dis}(\mathbf{h}_{t-j}, \mathbf{x}_{t-j}^n)$ は、注視位置 \mathbf{h}_{t-j} と選手 p_t^n の位置 \mathbf{x}_{t-j}^n 間のユークリッド距離であり、 γ_{t-j}^{mn} は $\text{dis}(\mathbf{h}_{t-j}, \mathbf{x}_{t-j}^n)$ を $[0, 1]$ 内に収める正規化パラメータである。 z_{t-j}^{mn} は、 \mathbf{h}_{t-j} が中心の半径 R の円形領域に位置する選手 p_t^n のエッジの強さが、 \mathbf{h}_{t-j} と \mathbf{x}_{t-j}^n 間のユークリッド距離に応じて減少することを示す。 図 5.4 は、先着領域と注視位置を用いて選手ネットワークを生成する例を示している。ただし、赤色の矢印は先着領域で生成された選手ネットワークを示し、オレンジ色の矢印は推定された注視位置から生成した選手ネットワークを示している。また、 \mathbf{h}_t は推定された注視位置を示す。これらより、周辺視野に基づいて注視位置の周囲の選手に対して重みをつけたネットワークを生成可能とする。

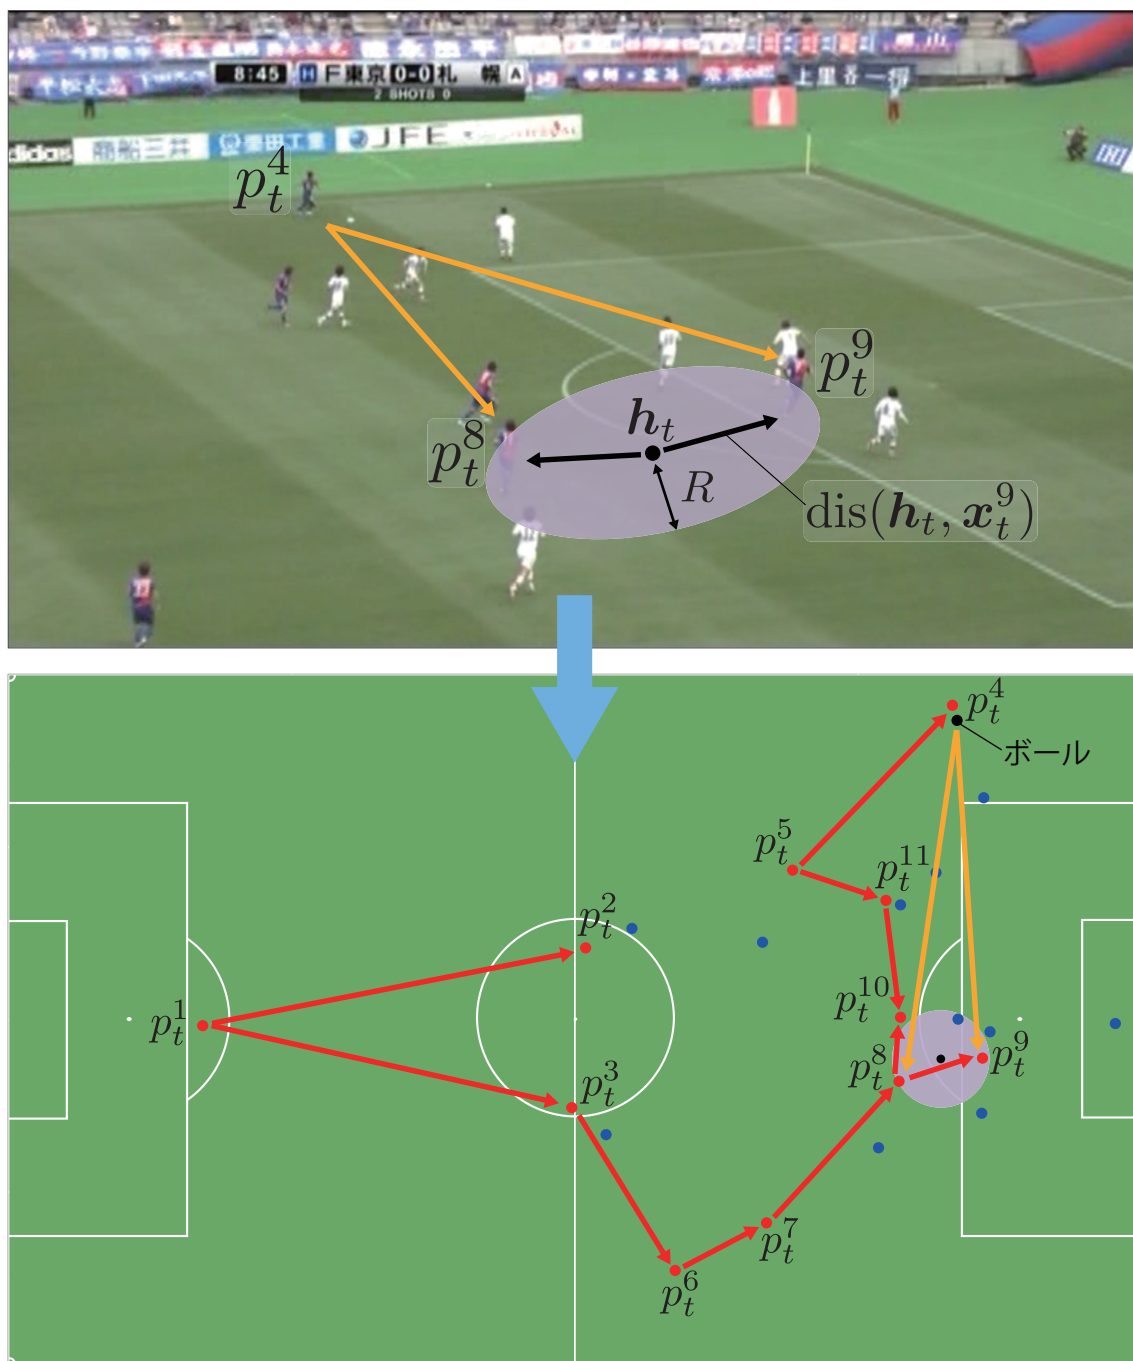


図 5.4: 先着領域および推定された注視位置に基づいて生成されたネットワークの例

5.3 HITS アルゴリズムに基づく選手の重要度の推定

本節では、HITS アルゴリズムに基づいた選手ネットワークにおける各選手の重要度の推定について説明する。HITS アルゴリズムは、リンク分析に基づき対象ネットワークに含まれる各ノードの authority スコアと hub スコアを算出する手法である [113]。authority スコアが高いノードは、より多くのノードからリンクされる。一方、hub スコアが高いノードは、より多くの authority ノードからリンクされる。HITS アルゴリズムは、これらのスコアの利用により重要なノードを発見することが可能となる。本手法では、パスの受け手候補となる各選手の重要度を authority スコアと定義し、この authority スコアを活用することで重要度の推定が実現される。5.2 で得られた選手ネットワーク L_t に対する HITS アルゴリズムの適用により、各選手の重要度が算出される。具体的に、選手 p_t^m の重要度 $\text{auth}_t^c(m)$ ($c = 1, 2, \dots, C$; C は総反復回数) は、次式で示される。

$$\text{auth}_t^c(m) = \varepsilon_t \sum_{n=1}^{11} L_t^{nm} \text{hub}_t^{c-1}(n) \quad (5.13)$$

$$\text{hub}_t^c(m) = \eta_t \sum_{n=1}^{11} L_t^{mn} \text{auth}_t^c(n) \quad (5.14)$$

ここで、 $\text{hub}_t^c(m)$ は hub スコア、 ε_t および η_t は正規化項を示す。ただし、authority スコア $\text{auth}_t^0(m)$ および hub スコア $\text{hub}_t^0(m)$ の初期値は 1 となる。本手法では、選手毎に authority スコアと hub スコアの更新を繰り返すことで、全選手の authority スコア $\text{auth}_t^C(m)$ が算出される。

以上により、先着領域と推定された注視位置から生成された選手ネットワークに対する HITS アルゴリズムの適用により、各選手の重要度推定が実現される。

5.4 実験

本節では、提案した選手の重要度推定手法の有効性を確認するために実際のサッカー映像を用いて重要度を推定する実験を行う。以降では、5.4.1で実験条件を示し、5.4.2で実験の結果および考察を行う。

5.4.1 実験条件

実験では、サッカー映像と TRACAB image tracking system¹により取得した選手・ボール位置データ (3,322 秒, 30 fps) を使用した。また、Tobii Eye Tracker 4C²を用いて、攻撃のポジションでサッカー経験を行った10年, 7年, 3年の被験者3名 ($S = 3$) から視線データを取得した。この時、少ない被験者数においても全被験者の注視位置の差を小さくするために、攻撃的な視点で視聴する簡単なタスクを設定した。具体的には、攻撃チームのゴールに貢献する次のパスの受け手を探しながらサッカーの映像を視聴するよう被験者に指示した。注視位置の推定モデルは、NVIDIA GeForce GTX 2080 Ti GPU を1つ用いて、2,943 秒のサッカー映像を学習して構築した。テストデータは、サッカー映像から抽出したパスシーン ($D = 57$) を用いた。各シーンの平均時間は8秒、合計時間は379秒である。実際にパスを受けた選手を Ground-truth としている。定量的に提案手法の有効性を示すために、次式の Recall@ k を用いた。

$$\text{Recall}@k = \frac{r_k}{D} \quad (k = 1, 2, \dots, K), \quad (5.15)$$

ここで、 r_k は、実際にボールを受け取った選手が重要度の高い k 上位の選手に含まれていた場面の数である。 k は解析対象となる選手の数である。今回の実験では、攻撃シーンが対象であることから、 k をゴールキーパーを除いた攻撃選手数の半分の5とした。

¹<https://chyronhego.com/products/sports-tracking/>

²<https://tobiigaming.com/eye-tracker-4c/>

1つの理想的な手法および6つの比較手法により比較を行い提案手法の有効性を示す。ただしPMは提案手法である。

理想的な手法 (IM) [121]

先着領域と経験者の視線データに基づいて生成された選手ネットワークに対して、HITS アルゴリズムを適用した本手法の理想的な手法である。選手ネットワークは、実際の経験者の視線データを用いて生成している。PMと比較を行うことで、注視位置推定モデルの再現性を示す。

比較手法1 (CM1) [122]

先着領域のみに基づいて生成された選手ネットワークを用いた手法である。PMとの比較により、LSTMモデルに基づいて推定された注視位置の利用の有効性を示す。

比較手法2 (CM2)

フォーメーション特徴量を用いずに、選手とボール位置データを用いて学習したLSTMから推定した注視位置と、先着領域に基づいて生成された選手ネットワークを利用した手法である。PMとの比較により、フォーメーション特徴量の有効性を示す。

比較手法3 (CM3)

提案手法のLSTMをTensorflow [109]による多変量回帰モデル [123]に置き換えた手法である。PMと比較することで、LSTMを用いることの有効性を示す。

比較手法4 (CM4)

PMからMフレームの投票処理を除いた手法である。PMとの比較により、注視位置の推定におけるMフレームの投票の有効性を検証する。

比較手法5 (CM5)

経験者の実際の注視位置に最も近い選手を、重要度の高い選手として選択する手法である。

比較手法6 (CM6)

表 5.2: 提案手法で用いたパラメータの詳細

詳細	パラメータ	値
調整パラメータ	α	$\frac{1}{3}$
先着領域の生成に関するパラメータ	V_{\max}	7.8
	β	1.3
	s	3.9
各系列の長さ	-	180
LSTM の入力ノード数	u_t	157
LSTM の隠れ層の数	-	3
LSTM の隠れ層のユニット数	-	256
LSTM の出力ノード数	h_t	2
投票処理のフレームサイズ	M	21
注視位置を用いたネットワーク生成に関するパラメータ	T'	60
	R	3
HITS アルゴリズムの反復回数	C	50

LSTM から推定される注視位置に最も近い選手を重要度の高い選手として選択する方法である。

CM5 と CM6 により先着領域に基づいて生成された選手ネットワークと HITS アルゴリズムの有効性を示す。表 5.2 には、提案手法で用いたパラメータの詳細が示されている。各手法のパラメータは、各手法の性能が最も高くなるように決定されている。

5.4.2 実験結果

表 5.3 に全手法の Recall@ k を示す。表より、PM の Recall が IM に最も近いことから、比較手法よりも PM が優れていることが示された。具体的には、PM および CM1 の結果の比較により、LSTM に基づいて推定した注視位置の有効性を確認した。次に、PM および CM2 の結果の比較により、フォーメーション特徴量を用いることの有効性が示された。加えて、PM が CM3 よりも値が高いため、LSTM 導入の有効性が示された。また、CM4 および PM の結果を比較することで、 M フレーム投票処理が提案手法の性能の向上に有効であることが示された。

表 5.3: 各手法の Recall@k

	$k = 1$	$k = 2$	$k = 3$	$k = 4$	$k = 5$
IM	0.807	0.842	0.877	0.895	0.912
PM	0.684	0.719	0.737	0.772	0.807
CM1	0.614	0.667	0.684	0.702	0.719
CM2	0.667	0.702	0.737	0.754	0.789
CM3	0.579	0.614	0.649	0.667	0.667
CM4	0.667	0.684	0.719	0.754	0.807
CM5	0.649	0.649	0.649	0.649	0.649
CM6	0.509	0.509	0.509	0.509	0.509

最後に、IM および PM がそれぞれ CM5 と CM6 よりも値が高いことから、HITS アルゴリズムを用いて選手の重要度を推定するために用いた、注視位置と先着領域による選手ネットワークの有効性を確認した。

次に、 α の重要性を検証するために、図 5.5 には、 α を $0, \frac{1}{3}, \frac{1}{2}, \frac{2}{3}, 1$ に変更して得られた提案手法の Recall@k が示されている。図 5.5 において、 α の値 1 と 0 の際は、CM1 と推定された注視位置のみから生成した選手ネットワークを活用して選手の重要度を推定する手法にそれぞれ対応する。得られた結果から、 $\alpha = \frac{1}{3}$ の際に、提案の値が最良になることが確認された。このことから、推定された注視位置に基づいた重み付き選手ネットワークの重要性が示された。

続いて、推定された注視位置の推定精度が「選手の重要度推定の成否」に及ぼす影響に関して考察を行うために、注視位置の推定性能の観点から、選手の重要度推定が成功した映像数と失敗した映像数の差に着目した。具体的には、表 5.4 に「推定された注視位置と実際の注視位置の差」と「選手の重要度推定の成功・失敗」の関係が示されている。表 5.4 において、距離は提案手法により推定された注視位置と実際の注視位置のユークリッド距離を示す。得られた結果から、推定された注視位置が正確でない場合、失敗した映像数が多くなっていることが示されている。一方、注視位置が正しく推定されている場合には、成功した映像数が増加している。

最後に、図 5.6-5.9 に PM, IM, および比較手法を用いて得られた選手の重要




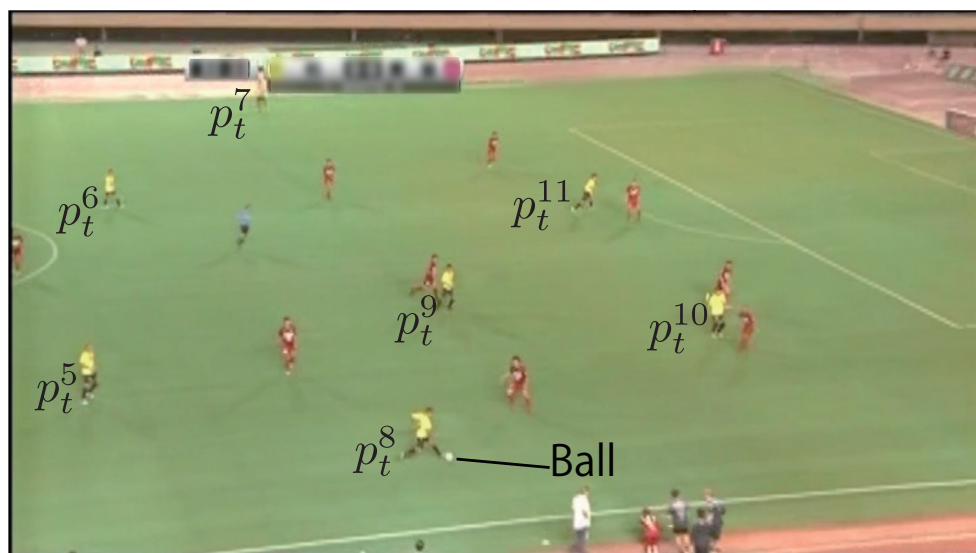
図 5.5: 提案手法の α を変化させた場合の Recall@k

度の推定結果が示されている。この図では、(a) は入力フレーム、(b) - (g) は各手法による重要度の推定結果である。図 (b) - (g) は、先着領域によって生成され選手ネットワークを赤矢印、注視位置によって生成された選手ネットワークをオレンジ色の矢印で示している。また、黒円で示された選手は、推定された重要度が高い選手であることを示しており、図 (b) - (c), (e) - (g) の紫色の領域は、実際の注視位置または推定された注視位置を中心とした式 5.12 に基づく半径 R の円が複数重ねられている。この映像では、選手 p_t^{11} が選手 p_t^8 からパスを受け取り、ゴールを決めた。得られた結果から、提案は IM と同様に選手 p_t^{11} の重要度が高くなることが示されている。具体的には、推定された注視位置から新たに選手 p_t^{11} へのリンクが生成されたため、選手の重要度の正確な推定が実現

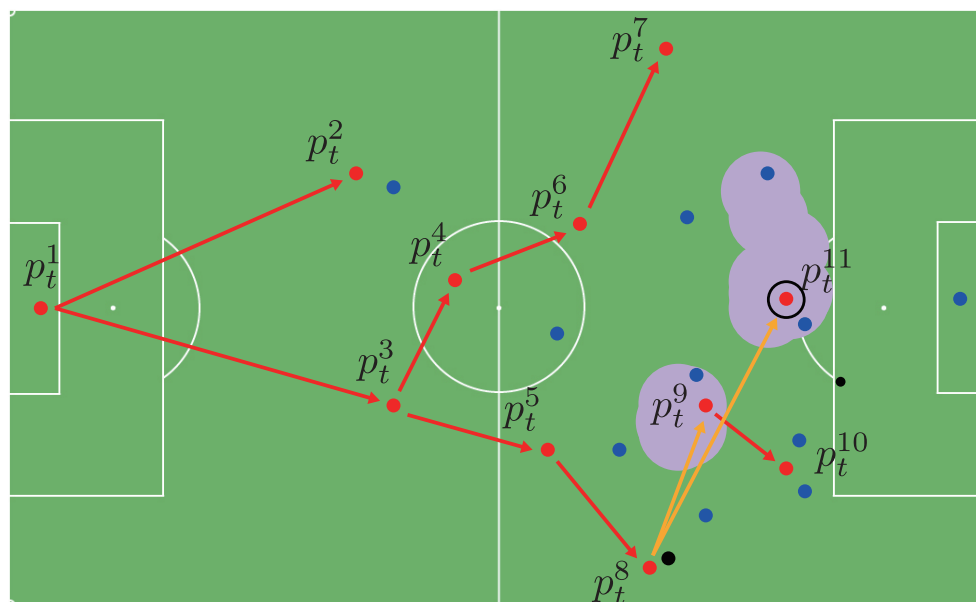
表 5.4: 「推定された注視位置と実際の注視位置の差」と「選手の重要度推定の成否」の関係

距離 [m]	成功したフレーム数	失敗したフレーム数
0 - 1	4	2
1 - 2	11	1
2 - 3	8	3
3 - 4	5	0
4 - 5	4	0
5 - 6	0	0
6 - 7	3	1
7 - 8	1	0
8 - 9	0	0
9 - 10	1	2
10 - 15	1	1
15 - 20	0	2
20 - 25	0	5
25 - 30	1	1

された。以上の通り、提案手法における推定された注視位置は、選手の重要度の推定に強く寄与していることが示された。




(a) 入力フレーム




(b) IM

図 5.6: 入力フレームと比較手法 (IM) から得られた重要度の推定結果




(c) PM




(d) CM1

図 5.7: 提案手法と比較手法 (CM1) から得られた重要度の推定結果




(e) CM2



(f) CM3

図 5.8: 比較手法 (CM2 および CM3) から得られた重要度の推定結果



(g) CM4

図 5.9: 比較手法 (CM4) から得られた重要度の推定結果

5.5 まとめ

本章では、映像視聴時におけるサッカー経験者の視線データを用いて、攻撃選手の重要度を算出する手法を提案した。本手法では、サッカー経験者の視線データを導入し、先着領域とその視線データによる注視位置推定モデルから選手ネットワークを生成した。その後、HITS アルゴリズムの適用により、攻撃チームの選手重要度を算出可能とした。最後に、サッカー映像を用いて重要度を推定する実験により提案手法の有効性が示された。したがって、サッカー競技に関する専門知識を戦術解析に導入することの有効性が示された。

第6章 結論

6.1 本研究の総括

本論文では、サッカー戦術や競技に関する知識を導入した深層学習手法の構築により、少量の学習データからの戦術解析を可能とする手法を新たに提案した。以降では、本論文の各章の概要を示す。

第2章では、サッカー映像からの戦術解析に関する従来研究を、本研究の関連研究として説明し本論文において解決すべき課題を明らかにした。第3章では、誤差逆伝搬法に基づかず、大量の学習データを必要としない識別器 Deep Extreme Learning Machine (DELIM) による戦術解析手法を構築した。具体的に、選手・ボール位置データから算出したチーム戦術に関する特徴量による学習によって、少量の学習データ量においても DELIM のパラメータが最適化され、従来のチーム戦術の推定手法と比較して高精度化が実現されることを明らかとした。第4章では、チームの戦術の関係性に基づく制約を導入したチーム戦術の推定手法を構築した。具体的に、第3章で構築した深層学習手法に、新たにチームの戦術の関係性に基づいた制約を導入して戦術の推定結果を補正する。これにより、対戦する2チームの戦術の組み合わせに基づいた最適な補正が実現され、チーム戦術推定の高精度化が可能となった。第5章では、サッカー経験者から取得した映像視聴時の視線データを用いた戦術解析手法を構築した。具体的に、サッカー映像を視聴する経験者の視線の動きが競技に関する専門知識と高い関連性を有していることに着目し、これを深層学習に導入した。これにより、サッカー競技に関する専門知識を導入することの有効性が示された。以上により、少量データからの学習を可能にする深層学習モデルを構築することで、サッカー映像からの高精度な戦術解析が実現した。

6.2 本研究の今後の課題

本論文では、サッカー戦術や競技に関する知識を導入した深層学習手法を提案することで、少量の学習データからのチーム戦術を解析することを可能とする手法を実現した。チーム戦術推定では、2次元の選手位置データを用いて基本戦術を推定した。一方で、個人戦術やグループ戦術解析の一部は、サッカー映像に撮像される選手の動きや姿勢に着目した解析が行われている。個人およびグループ戦術はチーム戦術との包括関係にあることから、パスやドリブルの姿勢など個人およびグループ戦術の解析結果等をチーム戦術を推定する深層学習の学習に活用することで、チーム戦術推定の更なる高精度化が実現されると考えられる。

また、他の団体スポーツ競技においても戦術解析の手法が種々提案されているが、機械学習における学習データの出力ラベル付与の観点から、サッカー競技と同様に解析に使用可能なデータ量が限られている。このため、今後は、本論文で構築した少量データにおける戦術解析手法を他の団体スポーツ競技に対しても適用することが求められる。

以上の2点が本研究における今後の課題としてまとめられる。

謝辞

本研究は、著者が北海道大学および北海道大学大学院に在学した期間、約5年間にわたって行ったものである。

本研究に関して、研究遂行のみならず、終始御指導および御鞭撻を頂きました長谷山美紀教授に心より深謝申し上げます。加えて、多くの国内・国外学会への参加、論文執筆、および教育活動等、様々な有益な機会を頂いたことに対しても、深くお礼申し上げます。

本論文をまとめるにあたり、御助言をいただきました、副査をお引き受けいただいた北海道大学大学院情報科学研究院 言語メディア学研究室 荒木健治教授、北海道大学大学院情報科学研究院 メディア創生学研究室 坂本雄児教授、北海道大学大学院情報科学研究院 情報メディア環境学研究室 土橋宜典教授、ならびに北海道大学大学院情報科学研究院 メディアダイナミクス研究室 小川貴弘准教授に深謝の意を表します。

本研究の遂行において、多大なる御助力を賜りました北海道大学工学研究院、高橋翔准教授に心よりお礼申し上げます。研究活動のみならず進学や日々の学生生活に関するご助言もいただけたこと、ご多忙の中においても真剣に対応していただきましたこと、深謝申し上げます。また、北海道大学 数理・データサイエンス教育研究センター 湧田雄基特任准教授、北海道大学 数理・データサイエンス教育研究センター 阿部真育特任准教授、釧路工業高等専門学校 創造工学科 斉藤直輝助教、北海道大学 数理・データサイエンス教育研究センター 藤後廉特任助教、ならびに北海道大学 総合IR室 前田圭介特任助教に深謝申し上げます。さらに、北海道大学在学における研究期間のみならず、著者が釧路工業高等専門学校在学時に研究活動や進学に関して、終始御指導、御鞭撻をいただいた釧路工業高等専門学校 創造工学科 浅水仁教授に深謝申し上げます。

著者の研究室の所属期間中，多くの御協力を賜りました北海道大学大学院情報科学院情報科学専攻メディアネットワークコースメディアダイナミクス研究室の先輩，同輩ならびに後輩学生の皆様に感謝申し上げます。皆様と共に高め合うことで，私は約5年間で研究を成し遂げることができました。

最後に，自分の進路に対して，日々温かく見守りおよび支援して下さった家族に深謝申し上げ謝辞とさせていただきます。

参考文献

- [1] 前田秀樹, サッカーの戦術 & 技術, 新星出版社, 2005.
- [2] S. McDonald, “Run the numbers: Here’s how much the global sports market could be worth by 2023.” <<https://footwearnews.com/2019/business/retail/global-sports-market-2019-statistics-1202804732/>>, 2019 (12/7/2020 access).
- [3] J.R. Wang and N. Parameswaran, “Survey of sports video analysis: research issues and applications,” in Proceedings of the Pan-Sydney Area Workshop on Visual Information Processing, pp.87–90, Citeseer, 2004.
- [4] C.B. Santiago, A. Sousa, M.L. Estriga, L.P. Reis, and M. Lames, “Survey on team tracking techniques applied to sports,” 2010 International Conference on Autonomous and Intelligent Systems, AIS 2010, pp.1–6, IEEE, 2010.
- [5] T. D’Orazio and M. Leo, “A review of vision-based systems for soccer video analysis,” Pattern Recognition, vol.43, no.8, pp.2911–2926, 2010.
- [6] S.F. de Sousa, A.d.A. Araújo, and D. Menotti, “An overview of automatic event detection in soccer matches,” 2011 IEEE Workshop on Applications of Computer Vision (WACV), pp.31–38, IEEE, 2011.
- [7] J. Gudmundsson and M. Horton, “Spatio-temporal analysis of team sports,” ACM Computing Surveys (CSUR), vol.50, no.2, pp.1–34, 2017.

- [8] H.C. Shih, “A survey of content-aware video analysis for sports,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol.28, no.5, pp.1212–1231, 2017.
- [9] J. Buschmann, H. Bussmann, and K. Pabst, *Coordination: A new approach to soccer coaching*, Meyer & Meyer Verlag, 2002.
- [10] M. Baccouche, F. Mamalet, C. Wolf, C. Garcia, and A. Baskurt, “Action classification in soccer videos with long short-term memory recurrent neural networks,” *International Conference on Artificial Neural Networks*, pp.154–159, 2010.
- [11] S. Alipour, P. Oskouie, and A.M. Eftekhari-Moghadam, “Bayesian belief based tactic analysis of attack events in broadcast soccer video,” in *Proceedings of the IEEE International Conference on Informatics, Electronics and Vision*, pp.612–617, 2012.
- [12] C. Perin, R. Vuillemot, and Jean-Daniel-Fekete, “Soccerstories: a kick-off for visual soccer analysis,” *IEEE Transactions on Visualization and Computer Graphics*, vol.19, no.12, pp.2506–2515, 2013.
- [13] M. Burenius, J. Sullivan, and S. Carlsson, “3d pictorial structures for multiple view articulated pose estimation,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.3618–3625, 2013.
- [14] T. Tsunoda, Y. Komori, M. Matsugu, and T. Harada, “Football action recognition using hierarchical lstm,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pp.99–107, 2017.
- [15] T. Decroos, L. Bransen, J. Van Haaren, and J. Davis, “Actions speak louder than goals: Valuing player actions in soccer,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp.1851–1861, 2019.

- [16] T. Decroos and J. Davis, “Player vectors: Characterizing soccer players’ playing style from match event streams,” *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pp.569–584, Springer, 2019.
- [17] 三須俊彦, 高橋正樹, 合志清一, 蓼沼眞, 藤田欣裕, and 八木伸行, “実時間画像処理に基づくオフサイドライン可視化システム,” *電子情報通信学会論文誌 D*, vol.88, no.8, pp.1681–1692, 2005.
- [18] G. Zhu, C. Xu, Q. Huang, Y. Rui, S. Jiang, W. Gao, and H. Yao, “Event tactic analysis based on broadcast sports video,” *IEEE Transactions on Multimedia*, vol.11, no.1, pp.49–67, 2009.
- [19] S. Takahashi and M. Haseyama, “Active grid-based pass region estimation from multiple frames of broadcast soccer videos,” *ITE Transactions on Media Technology and Applications*, vol.1, no.3, pp.220–225, 2013.
- [20] J. Perl, A. Grunz, and D. Memmert, “Tactics analysis in soccer—an advanced approach,” *International Journal of Computer Science in Sport*, vol.12, no.1, pp.33–44, 2013.
- [21] K. Knauf and U. Brefeld, “Spatio-temporal convolution kernels for clustering trajectories,” in *Proceedings of the Workshop on Large-Scale Sports Analytics*, pp.109–118, 2014.
- [22] V. Vercruyssen, L. De Raedt, and J. Davis, “Qualitative spatial reasoning for soccer pass prediction,” in *Proceedings of CEUR Workshop*, 2016.
- [23] S. Ohnuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Team tactics estimation from soccer videos based on fuzzy clustering,” in *Proceedings of International Conference on Circuits Systems, Computers and Communications*, 2012.

- [24] X. Wei, L. Sha, P. Lucey, S. Morgan, and S. Sridharan, “Large-scale analysis of formations in soccer,” *Digital Image Computing: Techniques and Applications (DICTA)*, 2013 International Conference on, pp.1–8, 2013.
- [25] P. Lucey, D. Oliver, P. Carr, J. Roth, and I. Matthews, “Assessing team strategy using spatiotemporal data,” in *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.1366–1374, 2013.
- [26] A. Bialkowski, P. Lucey, P. Carr, Y. Yue, and I. Matthews, “Win at home and draw away: Automatic formation analysis highlighting the differences in home and away team behaviors,” in *Proceedings of 8th Annual MIT Sloan Sports Analytics Conference*, pp.1–7, Citeseer, 2014.
- [27] C. Zhou, X. Wang, J. Li, and C. Wen, “Soccer videos analysis based on the active discriminant model,” in *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*, vol.2015-Novem, pp.656–659, 2015.
- [28] T.R.F. Warnakulasuriya, X. Wei, C. Fookes, S. Sridharan, and P. Lucey, “Discovering methods of scoring in soccer using tracking data,” in *Proceedings of the 2015 KDD Workshop on Large-Scale Sports Analytics*, pp.1–4, KDD Workshop on Large-Scale Sports Analytics, 2015.
- [29] Y. Wu, X. Xie, J. Wang, D. Deng, H. Liang, H. Zhang, S. Cheng, and W. Chen, “Forvizor: Visualizing spatio-temporal team formations in soccer,” *IEEE Transactions on Visualization and Computer Graphics*, vol.25, no.1, pp.65–75, 2018.
- [30] T. Decroos, J. Van Haaren, and J. Davis, “Automatic discovery of tactics in spatio-temporal soccer match data,” in *Proceedings of the 24th ACM SIGKDD*

- International Conference on Knowledge Discovery & Data Mining, pp.223–232, 2018.
- [31] A. Krizhevsky, I. Sutskever, and G.E. Hinton, “Imagenet classification with deep convolutional neural networks,” *Communications of the ACM*, vol.60, no.6, pp.84–90, 2017.
- [32] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv:1409.1556*, 2014.
- [33] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, “Inception-v4, inception-resnet and the impact of residual connections on learning,” *arXiv preprint arXiv:1602.07261*, 2016.
- [34] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp.770–778, 2016.
- [35] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, “Going deeper with convolutions,” in *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, pp.1–9, 2015.
- [36] S.J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Transactions on Knowledge and Data Engineering*, vol.22, no.10, pp.1345–1359, 2009.
- [37] N. Tajbakhsh, J.Y. Shin, S.R. Gurudu, R.T. Hurst, C.B. Kendall, M.B. Gotway, and J. Liang, “Convolutional neural networks for medical image analysis: Full training or fine tuning?,” *IEEE Transactions on Medical Imaging*, vol.35, no.5, pp.1299–1312, 2016.

- [38] L. Mou, Z. Meng, R. Yan, G. Li, Y. Xu, L. Zhang, and Z. Jin, “How transferable are neural networks in nlp applications?,” arXiv preprint arXiv:1603.06111, 2016.
- [39] E. Cambria, G.B. Huang, L.L.C. Kasun, H. Zhou, C.M. Vong, J. Lin, J. Yin, Z. Cai, Q. Liu, and K.L. et al., “Extreme learning machines [trends & controversies],” *IEEE Intelligent Systems*, vol.28, no.6, pp.30–59, 2013.
- [40] A.M. Williams, K. Davids, L. Burwitz, and J.G. Williams, “Visual search strategies in experienced and inexperienced soccer players,” *Research Quarterly for Exercise and Sport*, vol.65, no.2, pp.127–135, 1994.
- [41] A. Roca, P.R. Ford, A.P. McRobert, and A.M. Williams, “Identifying the processes underpinning anticipation and decision-making in a dynamic time-constrained task,” *Cognitive Processing*, vol.12, no.3, pp.301–310, 2011.
- [42] K. Matsumoto, S. Sudo, H. Saito, and S. Ozawa, “The ball tracking method by integration of multi-viewpoint images for camera viewpoint selection in soccer game broadcasting,” *IEEJ Transactions on Electronics, Information and Systems*, vol.121, no.10, pp.1530–1539, 2001.
- [43] P.J. Figueroa, N.J. Leite, and R.M. Barros, “Tracking soccer players aiming their kinematical motion analysis,” *Computer Vision and Image Understanding*, vol.101, no.2, pp.122–135, 2006.
- [44] V. Pallavi, J. Mukherjee, A.K. Majumdar, and S. Sural, “Ball detection from broadcast soccer videos using static and dynamic features,” *Journal of Visual Communication and Image Representation*, vol.19, no.7, pp.426–436, 2008.
- [45] J. Liu, X. Tong, W. Li, T. Wang, Y. Zhang, and H. Wang, “Automatic player detection, labeling and tracking in broadcast soccer video,” *Pattern Recognition Letters*, vol.30, no.2, pp.103–113, 2009.

- [46] Y.C. Jiang, K.T. Lai, C.H. Hsieh, and M.F. Lai, "Player detection and tracking in broadcast tennis video," *Pacific-Rim Symposium on Image and Video Technology*, pp.759–770, Springer, 2009.
- [47] M. Kristan, J. Perš, M. Perše, and S. Kovačič, "Closed-world tracking of multiple interacting targets for indoor-sports applications," *Computer Vision and Image Understanding*, vol.113, no.5, pp.598–611, 2009.
- [48] 片岡裕雄 and 青木義満, "単眼カメラを用いたサッカー戦術解析のための複数選手とボールの追跡," *画像電子学会誌*, vol.41, no.2, pp.152–159, 2012.
- [49] K. Soomro, S. Khokhar, and M. Shah, "Tracking when the camera looks away," in *Proceedings of 2015 IEEE International Conference on Computer Vision Workshop (ICCVW)*, pp.742–750, 2015.
- [50] J. Kurano, M. Hayashi, T. Yamamoto, H. Kataoka, M. Tanabiki, J. Furuyama, and Y. Aoki, "Ball trajectory extraction in team sports videos by focusing on ball holder candidates for a play search and 3d virtual display system," *Journal of Signal Processing*, vol.19, no.4, pp.147–150, 2015.
- [51] 大内一成, 小林大祐, 中洲俊信, and 青木義満, "ラグビー映像解析システムの開発," *電子情報通信学会論文誌 B*, vol.100, no.12, pp.941–951, 2017.
- [52] J. Komorowski, G. Kurzejamski, and G. Sarwas, "Deepball: Deep neural-network ball detector," *arXiv preprint arXiv:1902.07304*, 2019.
- [53] P. Chang, M. Han, and Y. Gong, "Extract highlights from baseball game video with hidden markov models," in *Proceedings of International Conference on Image Processing*, pp.I–I, IEEE, 2002.
- [54] R. Leonardi, P. Migliorati, and M. Prandini, "Semantic indexing of soccer audio-visual sequences: A multimodal approach based on controlled markov

- chains,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol.14, no.5, pp.634–643, 2004.
- [55] W.N. Lie and S.H. Shia, “Combining caption and visual features for semantic event classification of baseball video,” in *Proceedings of the 2005 IEEE International Conference on Multimedia and Expo*, pp.1254–1257, IEEE, 2005.
- [56] C.L. Huang, H.C. Shih, and C.Y. Chao, “Semantic analysis of soccer video using dynamic bayesian network,” *IEEE Transactions on Multimedia*, vol.8, no.4, pp.749–760, 2006.
- [57] Y.M. Su and C.H. Hsieh, “A novel model-based segmentation approach to extract caption contents on sports videos,” in *Proceedings of the 2006 IEEE International Conference on Multimedia and Expo*, pp.1829–1832, IEEE, 2006.
- [58] Y. Zhang, C. Xu, Y. Rui, J. Wang, and H. Lu, “Semantic event extraction from basketball games using multi-modal analysis,” in *Proceedings of the 2007 IEEE International Conference on Multimedia and Expo*, pp.2190–2193, IEEE, 2007.
- [59] M.A. Refaey, W. Abd-Almageed, and L.S. Davis, “A logic framework for sports video summarization using text-based semantic annotation,” in *Proceedings of the 2008 Third International Workshop on Semantic Media Adaptation and Personalization*, pp.69–75, IEEE, 2008.
- [60] N. Nitta, Y. Takahashi, and N. Babaguchi, “Automatic personalized video abstraction for sports videos using metadata,” *Multimedia Tools and Applications*, vol.41, no.1, pp.1–25, 2009.
- [61] J. Nichols, J. Mahmud, and C. Drews, “Summarizing sporting events using twitter,” in *Proceedings of the 2012 ACM International Conference on Intelligent User Interfaces*, pp.189–198, ACM, 2012.

- [62] G. Li, S. Ma, and Y. Han, “Summarization-based video caption via deep neural networks,” in Proceedings of the 23rd ACM International Conference on Multimedia, pp.1191–1194, ACM, 2015.
- [63] S. Nepal, U. Srinivasan, and G. Reynolds, “Automatic detection of ‘goal’ segments in basketball videos,” in Proceedings of the ninth ACM international conference on Multimedia, pp.261–269, ACM, 2001.
- [64] N. Babaguchi, Y. Kawai, and T. Kitahashi, “Event based indexing of broadcasted sports video by intermodal collaboration,” IEEE Transactions on Multimedia, vol.4, no.1, pp.68–75, 2002.
- [65] N. Babaguchi, K. Ohara, and T. Ogura, “Learning personal preference from viewer’s operations for browsing and its application to baseball video retrieval and summarization,” IEEE Transactions on Multimedia, vol.9, no.5, pp.1016–1025, 2007.
- [66] T. D’Orazio, M. Leo, P. Spagnolo, M. Nitti, N. Mosca, and A. Distanto, “A visual system for real time detection of goal events during soccer matches,” Computer Vision and Image Understanding, vol.113, no.5, pp.622–632, 2009.
- [67] W.L. Lu, K. Okuma, and J.J. Little, “Tracking and recognizing actions of multiple hockey players using the boosted particle filter,” Image and Vision Computing, vol.27, no.1-2, pp.189–205, 2009.
- [68] C. Poppe, S. De Bruyne, and R. Van de Walle, “Generic architecture for event detection in broadcast sports video,” in Proceedings of the 3rd International Workshop on Automated Information Extraction in Media Production, pp.51–56, ACM, 2010.
- [69] M.S. Dao and N. Babaguchi, “A new spatio-temporal method for event detection and personalized retrieval of sports video,” Multimedia Tools and Applications, vol.50, no.1, pp.227–248, 2010.

- [70] T. Decroos, V. Dzyuba, J. Van Haaren, and J. Davis, “Predicting soccer highlights from spatio-temporal match event streams,” AAAI, pp.1302–1308, 2017.
- [71] A. Cioppa, A. Deliege, S. Giancola, B. Ghanem, M.V. Droogenbroeck, R. Gade, and T.B. Moeslund, “A context-aware loss function for action spotting in soccer videos,” in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.13126–13136, 2020.
- [72] T. Haruyama, S. Takahashi, T. Ogawa, and M. Haseyama, “Multimodal important scene detection in far-view soccer videos based on single deep neural architecture,” ITE Transactions on Media Technology and Applications, vol.8, no.2, pp.89–99, 2020.
- [73] R. Shah and R. Romijnders, “Applying deep learning to basketball trajectories,” arXiv preprint arXiv:1608.03793, 2016.
- [74] K.C. Wang and R. Zemel, “Classifying nba offensive plays using neural networks,” in Proceedings of MIT Sloan Sports Analytics Conference, pp.1–9, 2016.
- [75] P. Pecev, M. Racković, and M. Ivković, “A system for deductive prediction and analysis of movement of basketball referees,” Multimedia Tools and Applications, vol.75, no.23, pp.16389–16416, 2016.
- [76] 林昌希 and 青木義満, “画像センシング技術によるチームスポーツ映像からのプレー解析,” 映像情報メディア学会誌, vol.70, no.9, pp.710–714, 2016.
- [77] 黒瀬龍之介, 林昌希, 石井壮郎, 岡村麻人, and 青木義満, “姿勢推定を用いたテニス映像の選手姿勢分析 (知覚情報次世代産業システム合同研究会・画像応用および画像処理一般),” 電気学会研究会資料. PI= The papers of Technical Meeting on” Perception Information”, IEE Japan,, pp.55–59, 電気学会, 2017.

- [78] G. Liu and O. Schulte, “Deep reinforcement learning in ice hockey for context-aware player evaluation,” arXiv preprint arXiv:1805.11088, 2018.
- [79] F.A. Gers, N.N. Schraudolph, and J. Schmidhuber, “Learning precise timing with lstm recurrent networks,” *Journal of Machine Learning Research*, vol.3, no.Aug, pp.115–143, 2002.
- [80] J. Pearl, *Probabilistic reasoning in intelligent systems: Networks of plausible inference*, Elsevier, 2014.
- [81] G. Pavlakos, X. Zhou, K.G. Derpanis, and K. Daniilidis, “Harvesting multiple views for marker-less 3d human pose annotations,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.6988–6997, 2017.
- [82] J. Donahue, L. Anne Hendricks, S. Guadarrama, M. Rohrbach, S. Venugopalan, K. Saenko, and T. Darrell, “Long-term recurrent convolutional networks for visual recognition and description,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.2625–2634, 2015.
- [83] L. Prokhorenkova, G. Gusev, A. Vorobev, A.V. Dorogush, and A. Gulin, “Catboost: unbiased boosting with categorical features,” *Advances in Neural Information Processing Systems*, pp.6638–6648, 2018.
- [84] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, *et al.*, “Scikit-learn: Machine learning in python,” *the Journal of Machine Learning Research*, vol.12, pp.2825–2830, 2011.
- [85] M.W. Berry, M. Browne, A.N. Langville, V.P. Pauca, and R.J. Plemmons, “Algorithms and applications for approximate nonnegative matrix factorization,” *Computational Statistics & Data Analysis*, vol.52, no.1, pp.155–173, 2007.

- [86] A. Doi, S. Fujiwara, K. Matsuda, and M. Kameda, “3d volume extraction and mesh generation using energy minimization techniques,” in Proceedings of the First International Symposium on 3D Data Processing Visualization and Transmission, pp.83–86, June 2002.
- [87] L.K.P.J. RDUSSEEUN and P. KAUFMAN, “Clustering by means of medoids,” 1987.
- [88] I.N. Junejo, O. Javed, and M. Shah, “Multi feature path modeling for video surveillance,” in Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004., pp.716–719, IEEE, 2004.
- [89] T. Taki and J.i. Hasegawa, “Visualization of dominant region in team games and its application to teamwork analysis,” in Proceedings Computer Graphics International 2000, pp.227–235, IEEE, 2000.
- [90] J. Chen, A.G. Cohn, D. Liu, S.s. Wang, J. Ouyang, and Q. Yu, “A survey of qualitative spatial representations,” Knowledge Engineering Review, vol.30, no.1, pp.106–136, 2013.
- [91] J.C. Bezdek, R. Ehrlich, and W. Full, “Fcm: The fuzzy c-means clustering algorithm,” Computers & Geosciences, vol.10, no.2-3, pp.191–203, 1984.
- [92] T. Cover and P. Hart, “Nearest neighbor pattern classification,” IEEE transactions on Information Theory, vol.13, no.1, pp.21–27, 1967.
- [93] J.A. Hartigan and M.A. Wong, “Algorithm as 136: A k-means clustering algorithm,” Journal of the Royal Statistical Society. Series C (applied statistics), vol.28, no.1, pp.100–108, 1979.
- [94] P. Lucey, A. Bialkowski, M. Monfort, P. Carr, and I. Matthews, “Quality vs quantity: Improved shot prediction in soccer using strategic features from spa-

- tiotemporal data,” in Proceedings of the 8th Annual MIT Sloan Sports Analytics Conference, pp.1–9, 2014.
- [95] G.B. Huang, Q.Y. Zhu, and C.K. Siew, “Extreme learning machine: A new learning scheme of feedforward neural networks,” in Proceedings of IEEE International Joint Conference on Neural Networks, pp.985–990, IEEE, 2004.
- [96] S. Ohnuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Soccer video segmentation based on team tactics estimation method,” in Proceedings of International Workshop on Advanced Image Technology, pp.692–695, 2013.
- [97] J. Wang, C. Xu, E. Chng, K. Wah, and Q. Tian, “Automatic replay generation for soccer video broadcasting,” in Proceedings of the 12th Annual ACM International Conference on Multimedia, pp.32–39, 2004.
- [98] X. Yu, C. Xu, H.W. Leong, Q. Tian, Q. Tang, and K.W. Wan, “Trajectory-based ball detection and tracking with applications to semantic analysis of broadcast soccer video,” in Proceedings of the Eleventh ACM International Conference on Multimedia, pp.11–20, 2003.
- [99] Laws of the Game, International Football Association Board, 2018.
- [100] J.C. Gower, G.B. Dijkstra, *et al.*, Procrustes problems, Oxford University Press on Demand, 2004.
- [101] Z. Zhang, “A flexible new technique for camera calibration,” IEEE Transactions on Pattern Analysis and Machine Intelligence, vol.22, no.11, pp.1330–1334, 2000.
- [102] C. Cortes and V. Vapnik, “Support-vector networks,” Machine learning, vol.20, no.3, pp.273–297, 1995.

- [103] 大貫修平, 高橋翔, and 小川貴弘, “ボール保持チームに注目したサッカー映像分割の高精度化に関する検討 (画像工学),” 電子情報通信学会技術研究報告: 信学技報, vol.112, no.434, pp.147–151, 2013.
- [104] X. Yu, H.W. Leong, J.H. Lim, Q. Tian, and Z. Jiang, “Team possession analysis for broadcast soccer video based on ball trajectory,” Fourth International Conference on Information, Communications and Signal Processing, 2003 and the Fourth Pacific Rim Conference on Multimedia. Proceedings of the 2003 Joint, pp.1811–1815, IEEE, 2003.
- [105] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Decision level fusion-based team tactics estimation in soccer videos,” in Proceedings of IEEE 5th Global Conference on Consumer Electronics, pp.58–59, IEEE, 2016.
- [106] V.C. Raykar, S. Yu, L.H. Zhao, A. Jerebko, C. Florin, G.H. Valadez, L. Bogoni, and L. Moy, “Supervised learning from multiple experts: whom to trust when everyone lies a bit,” in Proceedings of the 26th Annual International Conference on Machine Learning, pp.889–896, ACM, 2009.
- [107] L. Breiman, “Random forests,” Machine learning, vol.45, no.1, pp.5–32, 2001.
- [108] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp.2818–2826, 2016.
- [109] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G.S. Corrado, A. Davis, J. Dean, M. Devin, *et al.*, “Tensorflow: Large-scale machine learning on heterogeneous distributed systems,” arXiv preprint arXiv:1603.04467, 2016.
- [110] B.L. Welch, “The generalization of student’s problem when several different population variances are involved,” Biometrika, vol.34, no.1/2, pp.28–35, 1947.

- [111] 瀧剛志 and 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微量とその応用,” 電子情報通信学会論文誌 D, vol.81, no.8, pp.1802–1811, 1998.
- [112] W. Zaremba, I. Sutskever, and O. Vinyals, “Recurrent neural network regularization,” arXiv preprint arXiv:1409.2329, 2014.
- [113] J.M. Kleinberg, “Authoritative sources in a hyperlinked environment,” Journal of the ACM, vol.46, no.5, pp.604–632, 1999.
- [114] A. Fujimura and K. Sugihara, “Quantitative evaluation of sport teamwork using generalized voronoi diagrams,” Transactions on Institute of Electronics, Information and Communication Engineers, D-II, vol.87, no.3, pp.818–828, 2004.
- [115] T. Watanabe, M. Haseyama, and H. Kitajima, “A soccer field tracking method with wire frame model from tv images,” in Proceedings of the IEEE International Conference on International Conference on Image Processing, pp.1633–1636, 2004.
- [116] G. Saon, H.K.J. Kuo, S. Rennie, and M. Picheny, “The IBM 2015 English conversational telephone speech recognition system,” arXiv preprint arXiv:1505.05899, 2015.
- [117] R. Socher, A. Perelygin, J. Wu, J. Chuang, C.D. Manning, A. Ng, and C. Potts, “Recursive deep models for semantic compositionality over a sentiment treebank,” in Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, pp.1631–1642, 2013.
- [118] E.L. Lehmann and G. Casella, Theory of point estimation, Springer Science & Business Media, 2006.

- [119] A. Graves and J. Schmidhuber, "Frame-wise phoneme classification with bidirectional lstm and other neural network architectures," *Neural Networks*, vol.18, no.5, pp.602–610, 2005.
- [120] C.D. Stine, M.R. Arterburn, and N. Stern, "Vision and sports: a review of the literature.," *Journal of the American Optometric Association*, vol.53, no.8, p.627, 1982.
- [121] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, "A method for predicting importance of attack players based on multiple gaze tracking data in soccer videos," in *Proceedings of the 2019 IEEE 8th Global Conference on Consumer Electronics (GCCE)*, pp.511–512, IEEE, 2019.
- [122] S. Takahashi and M. Haseyama, "A method of important player extraction based on link analysis in soccer videos," *ITE Transactions on Media Technology and Applications*, vol.5, no.2, pp.42–48, 2017.
- [123] G. Chamberlain, "Multivariate regression models for panel data," *Journal of econometrics*, vol.18, no.1, pp.5–46, 1982.

著者の研究業績

論文

(A) 学会誌

- [A-1] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Team tactics estimation in soccer videos based on a deep extreme learning machine and characteristics of the tactics,” *IEEE Access*, vol. 7, pp. 153238–153248, 2019. (2018 IF:4.098).
- [A-2] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “A method for player importance prediction from player network using gaze position estimated by LSTM,” *ITE Transactions on Media Technology and Applications*, vol. 8, no. 3, pp. 151–160, 2020.

(B) 国際学会

- [B-1] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Decision level fusion-based team tactics estimation in soccer videos,” in *Proceedings of 2016 IEEE 5th IEEE Global Conference on Consumer Electronics*, 2016, pp. 58–59.
- [B-2] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Team tactics estimation in soccer videos via deep extreme learning machine based on players formation,” in *Proceedings of 2018 IEEE 7th Global Conference on Consumer Electronics*, 2018, pp. 85–86.
- [B-3] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “Field position estimation in soccer videos using convolutional neural network-based image feature,”

in *Proceedings of 2019 joint International Workshop on Advanced Image Technology & International Forum on Medical Imaging in Asia*, 2019, p. 110490Y.

[B-4] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “A method for predicting importance of attack players based on multiple gaze tracking data in soccer videos,” in *Proceedings of 2019 IEEE 8th Global Conference on Consumer Electronics*, 2019, pp. 520–521.

[B-5] G. Suzuki, K. Maeda, T. Ogawa, and M. Haseyama, “Quantitative analysis of engineer ’ s skill using wearable sensor data while inspecting highway bridge,” in *Proceedings of 2020 IEEE 2nd Global Conference on Life Sciences, and Technologies*, 2020, pp. 111–112.

[B-6] G. Suzuki, S. Takahashi, T. Ogawa, and M. Haseyama, “An estimation method of candidate region for superimposing information based on gaze tracking data in soccer videos,” in *Proceedings of 2020 IEEE International Conference on Consumer Electronics-Taiwan*, 2020.

(C) 技術報告

[C-1] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “Deep Extreme Learning Machine に基づくサッカー映像に撮像されたフィールド位置の推定に関する検討,” 映像情報メディア学会技術報告, vol. 41, no. 29, pp. 25-28, 2017.

[C-2] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “再帰型ニューラルネットワークを用いたサッカー映像における基本戦術の推定に関する検討,” 映像情報メディア学会技術報告, vol. 42, no. 4, pp. 131-135, 2018.

[C-3] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “サッカー映像視聴時の視線データを用いた攻撃選手の重要度算出に関する検討,” 映像情報メディア学会技術報告, vol. 43, no. 5, pp. 355-359, 2019.

[C-4] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “サッカー映像視聴時の複数の視線データを用いた攻撃選手の重要度算出に関する検討,” 第 22 回 画像の認識・理解シンポジウム (MIRU2019), pp. 1-4, 2019.

[C-5] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “サッカー映像視聴時の視線データを用いた情報の提示領域の算出に関する検討,” 映像情報メディア学会技術報告, vol. 44, no. 6, pp. 91-95, 2020.

(D) 講演発表

[D-1] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “サッカー映像における戦術の関係性に注目した戦術グループ推定の高精度化に関する検討,” 電気・情報関係学会北海道支部連合大会 講演論文集, pp. 160-161, 2016.

[D-2] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “深層学習に基づく特徴量を用いたサッカー映像に撮像されたフィールド位置の推定に関する検討,” 電気・情報関係学会北海道支部連合大会 講演論文集, pp. 20-21, 2018.

[D-3] 鈴木 元樹, 高橋 翔, 小川 貴弘, 長谷山 美紀, “サッカー映像視聴時の視線データを用いた周辺視に基づく攻撃選手の重要度算出に関する検討,” 電気・情報関係学会北海道支部連合大会 講演論文集, pp. 120-121, 2019.

(E) 受賞

[E-1] 日本最大の学生向けハッカソン型 IT コンテスト JPHACKS2018 地区大会 最優秀賞 (2018 年 10 月)

[E-2] 日本最大の学生向けハッカソン型 IT コンテスト JPHACKS2018 全国大会 企業賞および特別賞 (2018 年 11 月)

[E-3] 日本最大の学生向けハッカソン型 IT コンテスト JPHACKS2019 全国大会 企業賞 (2019 年 11 月)

[E-4] 令和元年度電気・情報関係学会北海道支部連合大会 若手優秀論文発表賞
(2019年11月)

[E-5] ライフイズテック株式会社 Mentor Award Commitment Award (2020年6
月)