

深層学習を用いたアメリカンフットボールにおける パスプレーのマッチアップ分析に関する研究†

山本 雄平*1・田中 成典*2・中村 健二*3・田中 ちひろ*4・姜 文淵*5・林 勲*2

我が国では、東京オリンピックに向けて、スポーツに関わる政策が積極的に推し進められている。その施策の一つである「スポーツ×ICT」では、スポーツ分野における計測機器の開発やデータ計測と可視化、そして新たなサービスの提案など、ICTの効果的な利活用方法が検討されている。筆者らは、これまでアメリカンフットボールに着目し、高性能なGNSSセンサと加速度センサを内蔵した計測端末を用いて、複数選手を可視化するシステムを開発してきた。このシステムを用いることで、指導者のみならず選手に対しても個々のプレーの振り返りの機会において有益な情報を提供できることを確認した。しかし、状況に応じたプレーの選択や、その成功率の提示といった戦術の分析までには至っていない。そこで、本研究では、パスプレーに関するオフenseとディフェンスのマッチアップ分析に深層学習を適用し、プレーの成功または失敗の推定の可能性を検討する。

キーワード：スポーツ情報学、アメリカンフットボール、パスプレー、マッチアップ分析、深層学習

1. はじめに

ラグビーワールドカップや東京オリンピック、関西ワールドマスターズゲームズなどの大規模なスポーツイベントの開催に伴い、スポーツの振興が期待されている。2015年に設置されたスポーツ庁[1]では、スポーツに関わる政策[2,3]を積極的に推し進めている。その施策の一つである「スポーツ×ICT」では、画像処理やセンシング機器による選手情報の取得とその可視化、そして新たなサービスの提案など、ICTの効果的な利活用方法が検討されている。特に、GPSに代表されるGNSS(Global Navigation Satellite System)センサや加速度センサなどの各種センサを内蔵したスポーツ向けのセンシング機器は、選手の走行距離やトップスピード、プレーエリアなどの個人に関わるものから、フォーメーションなどのチーム全体に関わるものまで、様々な情報を高精度に計測し、定量的に評価できることから、その応用が期待されている。

このような背景の下、筆者らは、カレッジスポーツの花形で、

しかも数100種類のプレーで戦術が組み立てられるアメリカンフットボールに着目し、ICTによる戦術分析を目指して研究を推進してきた。具体的には、パスプレーを計測し、そのデータを解析することで結果を予測して、選手交代のタイミングの把握やプレー中における作戦の適宜変更といった戦術に関する新たな気づきを獲得することを最終目標としてきた。

そこで、戦術分析のベースとなる選手やボールの軌跡の獲得方法に着目した。関連研究では、画像処理を用いて、選手やボールを追跡する方法[4-7]が提案されている。しかし、選手が密集する箇所においてオクルージョンが生じ、選手の識別精度が低下する課題がある。これに対して、著者らは、選手の識別や位置特定の精度向上を目的として、単視点多眼の映像に深層学習を適用して選手を識別する手法[8]を提案した。しかし、この研究では、選手の識別と位置特定の実現に留まっており、戦術分析に適用可能な軌跡の取得には至っていない。

そのため、戦術分析の実現に向けた取り組みとして、高性能なGNSSセンサと加速度センサを内蔵した計測端末[9]を用いて、複数選手の位置情報や移動軌跡から戦術分析を試みてきた。その第一歩として、アメリカンフットボールの監督やコーチ、選手へのヒアリングを通じて、戦術分析を行うための選手可視化システム[10,11]の開発を行った。その発展として、戦術分析に重要なフォーメーションのリアルタイムな可視化システム[12]も開発した。これらのシステムを用いることで、指導者のみならず選手に対しても個々のプレーを振り返る機会において有益な情報を提供できることを確認した。しかし、既存システム[10-12]では、状況に応じたプレーの選択や、その成功率などの定量的な戦術分析の実現には至っていない。

戦術分析に関する既存研究[13-17]では、プレーの分類・認識[13-15]、フォーメーション分析[16,17]を行う研究が主流となっている。前者[13-15]では、画像処理により得られた選手の移動軌跡から、オフenseプレーにおけるプレー属性を分類している。これにより、監督やコーチが対戦相手の動きのパ

† Research for Matchup Analysis of Pass Play in American Football with Deep Learning

Yuhei YAMAMOTO, Shigenori TANAKA, Kenji NAKAMURA, Chihiro TANAKA, Wenyan JIANG, and Isao HAYASHI

*1 大阪工業大学情報科学部

Faculty of Information Science and Technology,
Osaka Institute of Technology

*2 関西大学総合情報学部

Faculty of Informatics, Kansai University

*3 大阪経済大学情報社会学部

Faculty of Information Technology and Social Sciences,
Osaka University of Economics

*4 関西大学大学院総合情報学研究科

Graduate School of Informatics, Kansai University

*5 関西大学先端科学技術推進機構

Organization for Research and Development of Innovative Science and Technology, Kansai University

ターンやその傾向をより効率的に把握できることが報告されている。

後者 [16, 17] では、戦術立案のために過去の試合の計測データからチームの戦術パターンを確認するためのシステムを開発する試み [16] や、オフェンスチームを自動認識しフォーメーションを検出する研究 [17] が行われている。既存研究 [16] では、プレーデータが蓄積されていることを前提として、ダウン数や残り距離、フォーメーション、ハッシュ、プレーの種類といった過去のプレーに関する情報を入力し、類似プレーを検索することから戦術傾向を把握することを目的としている。しかし、検索結果を解釈するノウハウが求められる上、プレー一つひとつの良し悪しを定量的に分析評価することが難しい。また、既存研究 [17] では、画像処理により、選手位置を特定してスクリーンラインやフォーメーションを可視化しているが、ポジションごとの選手の巧拙や選手間の相性の判断といったプレーの分析は実現できていない。加えて、画像処理による選手位置推定の精度面の問題も見られる。

これらの既存研究の調査結果から、アメリカンフットボールに関する研究では、主に画像処理による選手のトラッキングを発展させ、戦術分析の可能性の追求へと動向が変化しつつあることがわかった。他のスポーツに着目すると、深層学習などの機械学習を用いることでスポーツの分析を高度化する事例 [18, 19] が見られる。具体的な取り組みとしては、バスケットボールへ深層学習を適用する事例 [18] や卓球のラリーを行うロボットの開発 [19] などがある。しかし、いずれの研究においても、著者らが目標とするプレーの予測に基づく戦術分析は取り組まれていない。

そこで、本研究では、ICT を活用したパスプレーの成功または失敗の推定の可能性を検討する。具体的には、アメリカンフットボールのパスプレーを対象として、既存システム [11] で描画した選手の軌跡画像に深層学習の一種である畳み込みニューラルネットワーク（以下、CNN: Convolutional Neural Network）を適用し、パス成否の予測ができるかを試行する。

本論文では、まず2章にて、本研究で対象とする戦術分析の目標と本研究の位置づけ、および事前に試行した可視化システムによるマッチアップ分析の結果について述べる。次に、3章にて、アメリカンフットボールに対して、深層学習を適用する方法について検討し、本研究の実験計画を立案する。そして、4章にて、深層学習による戦術分析の実現可能性に関する検証実験について述べる。5章では、深層学習を適用したパスプレーのマッチアップ分析を試行し、最後に、6章にて本研究を総括する。

2. 戦術分析の目的と手段

2.1 戦術分析の最終目標と本研究の位置づけ

著者らは、ICT を活用してスポーツにおけるプレーの巧拙や勝敗を予測することで、戦術立案を支援する新たな戦術分析の実現を研究の最終目標としている。プレーの予測により、プレー中における選手交代のタイミングの把握やプレーコールの変更など、予測結果に基づく戦術を再考するきっかけとなる新たな気づきを提供できると考える。

この考え方にに基づき、選手の軌跡の可視化結果と動画を併用した手作業によるマッチアップ分析 [11] を実施した結果、パス成否には、WR が戦術通りの動きをしたかどうかや、WR と DB の距離や位置関係などが影響するという知見が得られた。従来の戦術分析では、監督やコーチが映像や実際のプレーから選手の動きを確認することで、これらの情報を読み取り総合的に判断している。このことから、選手の移動軌跡には、パス成功や失敗に関わる何らかの特徴が内在していると考えられる。そのため、軌跡画像を深層学習により機械的に学習することで、パス成否を推定し、プレーを予測できる可能性があると言える。

そこで、本研究では、これらの点に着目して、選手の起用や戦術の立案に関する有益な情報を指導者に提供するため、深層学習を用いて画像から選手間の位置関係の特徴を自動的に抽出し、そこからプレーの成否を予測できるかを検証する。実験では、まず、深層学習の適用時に必要となる軌跡画像の生成手段を検討する。次に、各手段で生成された画像を用いて推定精度を検証する。最後に、深層学習によるパス成否の推定結果と既存研究 [11] のマッチアップ分析の結果とを比較することで、深層学習から定量的なマッチアップ分析の実現可能性を確認する。

2.2 アメリカンフットボールにおける戦術分析

アメリカンフットボールは、相手の陣地にボールを選び得点を競うスポーツである。攻撃にはパスプレーとランプレーがあり、中でもパスプレーは試合の展開を大きく左右する。パスプレーでは、試合形式のプレー以外に、オフェンス対ディフェンスのマッチアップの練習が行われている。マッチアップは、投球者であるクォーターバック（以下、QB）と捕球者であるワイドレシーバ（以下、WR）、その動きを阻害するディフェンスバック（以下、DB）の3つのポジションの選手が1人ずつ参加して行われる。QB は、プレー開始時から WR と DB の位置や動きを見ながら、パス成功率を判断している。そして、成功率が高いタイミングで WR にボールを投げる。そのため、各選手の動きを把握することが非常に重要である。そこで、本研究では、QB、WR、DB の軌跡を利用することで、パスプレーにおける戦術分析の実現を試みる。

2.3 可視化システムによるマッチアップ分析

2.3.1 マッチアップ分析の目的

本節では、選手のトラッキング情報を目視で確認できる可視化システム（図1）[11] を用いて、オフェンスとディフェンスのマッチアップ分析を行う。そして、目視により読み取れる情報からマッチアップ分析が可能かを確認する。この結果は、5章にて後述する深層学習によるマッチアップ分析の検証に用いる。

2.3.2 分析方法

可視化システム [11] を用いて、パスプレーの要のポジションである QB、WR、DB を対象に目視で分析する。パス成否を分ける特徴として、選手の移動軌跡の長さや選手間の距離な

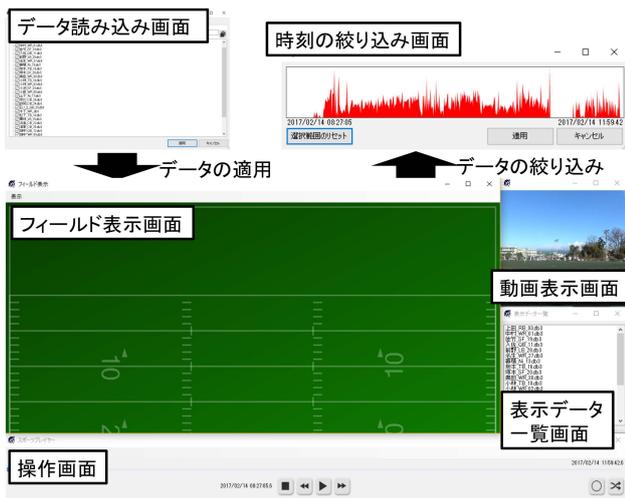


図1 可視化システム

ど、軌跡画像から読み取れる特徴があるかどうかの観点に基づき分析を行う。

2.3.3 分析データ

分析に用いる計測データを表1に示す。これらのデータは、関西大学アメリカンフットボール部の協力の下、GPSports [9]を用いて関西大学千里山キャンパスでの練習を計測したものである。なお、図2と表1のプレーパターン番号は対応している。パターン1と2は、QBとWRのパスプレーの練習であり、DBがない場合といる場合の数十種類のパスコースのパターンが含まれている。一方、パターン3と4は、実際の試合または実戦に近い形式での練習であり、ディフェンスがいる場合といない場合の約100~150種類のフォーメーションが含まれる。この内、パターン3は、複数のWRがプレーしているものの、パス受けるのは1人のWRに限定される。そのため、表1では、QBとパスを受けたWRの組み合わせのみに着目し、その組み合わせをパターン1のプレーとして集計した。

また、データ計測では、GPSportsにより実測したデータの他にも、プレーに関する情報を目視で記録する。たとえば、1プレーに出場した選手の一覧、プレーの開始時刻、QBの投球時刻、WRまたはDBの捕球時刻、プレーの終了時刻に関しても、複数人の目視により手作業で記録した。しかし、既存研究 [16] で述べられている通り、プレーに影響を与える可能性のあるデータは、選手の位置情報やポジションなどの他に、ダウン数や残り距離などの試合状況に関する情報（表2の試合状況や環境）も考慮する必要があるが、今回は考慮しなかった。

本研究では、4つのパターンの内、マッチアップであるパターン2の計測データを利用する。

2.3.4 マッチアップ分析の結果と考察

本項では、計測したデータから、戦術分析の可能性を検証するため、図2に示すパターン2におけるオフenseとディフェンスのマッチアップの可視化結果を用いて、プレー分析を試みる。パターン2のプレーを詳細に確認した結果、次のことが明

表1 計測データ

計測の日付 (2017年)	計測したプレー数 (件)			
	パターン1	パターン2	パターン4	合計
2月12日	0	27	20	47
2月19日	0	0	10	10
2月20日	0	41	34	75
2月24日	67	0	0	67
3月17日	186	0	5	191
3月26日	25	0	21	46
3月31日	100	0	59	159

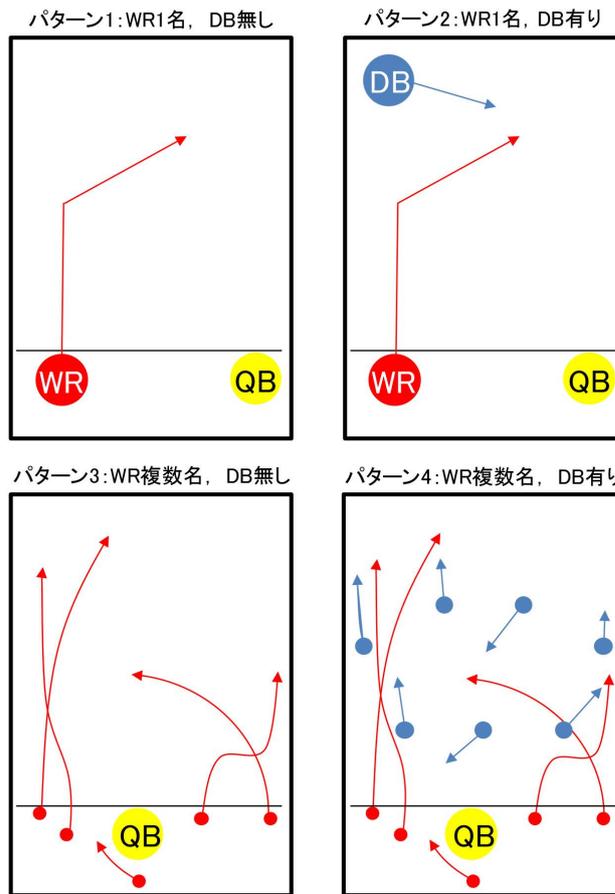


図2 計測データのプレーパターン

らかとなった。

- WRへのパス成否の傾向を確認できる

パターン2のパスプレーにおいて、特定のQBからのパスを特定のWRがキャッチする事例では、パスにかかった時間(QBが投げた時からWRがキャッチに成功または失敗した時点までの時間)内の軌跡の長さによって、パス成否が異なる傾向が見られた。プレーを可視化して詳細を確認したところ、軌跡が非常に短い場合はパスが成功しており、それ以外の場合はパス失敗が多いことがわかった。この要因について動画で確認すると、パスが成功している場合は、QBがパスをした時点でWRは一旦停止しQBの方を向き、ボールが飛んでくるのを待つ余裕があったことがわかった。このことから、可視化した軌跡の長さやパスにかかった時間を可視化することで、パスプ

表2 試合状況に関する情報

求められる情報の種類	パターン1	パターン2	パターン3	パターン4	
選手	オフェンス選手のポジション	入力 (2名)	入力 (2名)	入力 (数名)	入力 (数名)
	オフェンス選手のレベル	入力 (2名)	入力 (2名)	入力 (数名)	入力 (数名)
	オフェンス選手の動作軌跡	入力 (2名)	入力 (2名)	入力 (数名)	入力 (数名)
	モーションの有無	-	-	入力	入力
	ディフェンス選手のポジション	-	入力 (1名)	-	入力 (数名)
	ディフェンス選手のレベル	-	入力 (1名)	-	入力 (数名)
	ディフェンス選手の動作軌跡	-	入力 (1名)	-	入力 (数名)
	プレー時間 (秒)	入力	入力	入力	入力
	プレー名	入力	入力	入力	入力
	試合状況	得点差	-	-	-
パス獲得ヤード		-	-	-	入力
ラン獲得ヤード		-	-	-	入力
フレッシュ回数		-	-	-	入力
クォーター数		-	-	-	入力
残り時間		-	-	入力	入力
ダウン数		-	-	入力	入力
ボール位置		-	-	入力	入力
フレッシュまでの距離		-	-	入力	入力
試合環境	天候, 温度と湿度, 風 (向きと強さ), グラウンド状況 (天然芝か人工芝), デイゲームかナイター, など				
結果	パス成否	出力	出力	出力	出力
	3ヤードの獲得可否	-	-	-	出力

レーの成功率を分析できる可能性があることがわかった。

• WR と DB の位置関係や距離からパス成否の傾向が確認できる

パターン2のパスプレーにおいて、QB から WR にパスをした時点のDBの位置を確認すると、DBとWRの位置関係によってパス成否が異なる傾向が見られた。この要因についてプレーを可視化して詳細に確認すると、WRとDBの距離が遠い場合は妨害される可能性が低くパスが成功しやすい傾向があることがわかった。逆に距離が近い場合には、DBにパスを妨害される可能性が高いことがわかった。このことから、プレー時の選手間の距離を可視化することで、パスプレーの成否の傾向を分析できる可能性があることがわかった。

2.3.5 プレー分析のまとめ

2つの事例から、オフェンスとディフェンスのマッチアップのプレー動向と併せてパス成功と失敗の結果を確認することで、走行距離や選手間の距離に基づき、選手の技量を分析できる可能性があることが明らかとなった。しかし、アメリカンフットボールは、個々の選手の能力以外に攻守の駆け引きがあり、瞬時に判断すべき事項が非常に多く、これらを数値的に把握して判断することは容易ではない。一方で、プレー分析の結果から、軌跡画像には、走行距離や選手間の距離以外にも、パス成否に関わる何らかの特徴が含まれていると言える。このことから、軌跡画像に深層学習を適用することで、これらの特徴を自動的に獲得して、機械的にパス成否を判断できる可能性

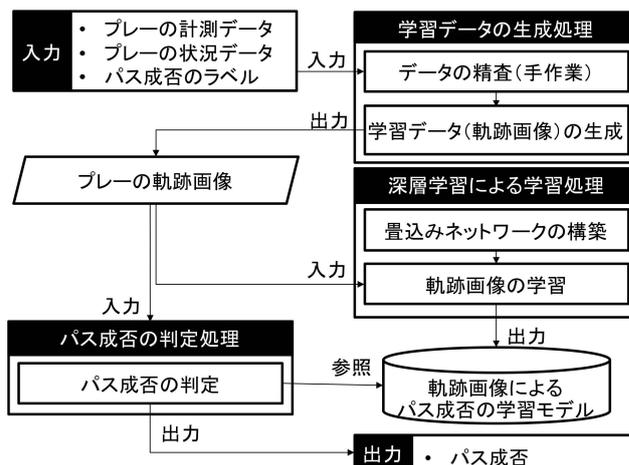


図3 深層学習の適用方針

が高い。本研究の提案が実現すれば、選手の移動軌跡や走行スピード、パスタイミングなどが実際のプレーと僅かに異なることによるパス成否の変化を獲得し、立案した戦術の有効性を事前に確認することができ、戦術分析の高度化に寄与できる。これにより、現在のプレーにおける問題点の把握や、今後のプレーの戦術を立案する時に監督やコーチ、選手にパスが成功しやすい領域や、最善のパスタイミングなど、戦術に重要な情報を提供できる可能性があると考えられる。

そのため、本研究では、高度な戦術分析の実現への第一歩として、深層学習を用いて、マッチアップのパスプレーにおける選手の軌跡画像からパス成否に関わる特徴を自動的に獲得し、パスプレーの成否が判別可能かを試行し、最終的に軌跡画像による学習モデルの有用性を検証する。

3. マッチアップ分析への深層学習の適用方針と実験計画

3.1 深層学習の適用方針

3.1.1 方針の概要

本研究では、深層学習によりプレーの計測データとそのプレーの成否の結果からプレーの成功確率が推定できるかを検証する。その適用方針を図3に示す。本研究で対象とするアメリカンフットボールは、1プレーが10秒程度で終わる特徴があり、その軌跡画像を生成するためには、プレーの計測データの他に開始時刻や終了時刻などの状況データが必要となる。また、深層学習の出力であるパス成功か失敗かの情報も必要となる。そのため、本研究では、これらの情報を用いて、学習データの生成処理、深層学習による学習処理と、パス成否の判定処理により、最終的にパス成否を推定する。

プレーの結果を深層学習に適用する場合、位置情報を可視化した画像を用いる方法と、計測した数値情報をベクトルとして用いる方法の2通りが考えられる。パスプレーの成否に関わる要因は複雑で、単純にベクトル化するだけではデータ間の関連性などを表現することが難しいことから、まずはプレーを可視化した軌跡画像をそのまま用いて深層学習による戦術分析の可能性を検討する。

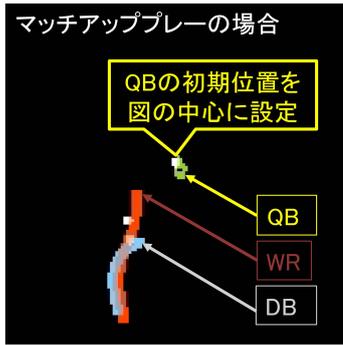


図4 軌跡画像の例

学習データの生成処理では、入力データに基づき、パス成功の軌跡画像（以下、正例）とパス失敗の軌跡画像（以下、負例）を生成する。パス成否を判断する場合、その要因の特徴が軌跡画像に表現されているという考えから、軌跡画像の最適な生成方法を明らかにする必要がある。

深層学習による学習処理では、CNN を用いて学習モデルを生成する。これは、入力された画像の特徴を自動的に獲得することで知られている。一方、時々刻々と変化するプレーのような時系列データを取り扱う場合、RNN（Recurrent Neural Network）などの適用も考えられる。しかし、本研究では、プレーの成功または失敗の推定の可能性を検討するために、プレーが完了している軌跡画像を用いることから CNN を選択した。

最後に、パス成否の判定処理では、パス成否の学習モデルを用いて、入力のパスプレーの成否を判定する。

3.1.2 学習データの生成方法

手作業により学習データの精査を行う。具体的な手順は次の通りである。

STEP1：

関西大学のアメリカンフットボール部の練習時に GPSports を装着してデータを計測する。（以下、実測データ）

STEP2：

分析に必要な情報として、1プレーに出場した選手の一覧、プレーの開始時刻、QBの投球時刻、WRまたはDBの捕球時刻、プレーの終了時刻を手作業により複数人で記録する。（以下、状況データ）

STEP3：

プレーの状況データで記録されている時刻と実測データの時刻には僅かな誤差が含まれることから、計測データのGNSS時刻に合わせるため、可視化システムを用いて同期させた動画と照合しながら1プレーずつ手作業で状況データの時刻を調整する。

可視化システム [11] を用いて、上記の手順で同期した状況データを参照しながら、実測データから1プレーごとの軌跡画像を生成する。選手の移動軌跡は、図1に示す通り、緑の背景

表3 データセットに関する実験項目

実験項目番号	実験項目	実験条件	
		実験条件1	実験条件2
A	データ件数	少ない件数に合わせて同数に揃える	全件を用いる
B	チャンネル数	3チャンネル (RGB)	1チャンネル (グレースケール)
C	拡張の有無	学習データを回転・反転により拡張	学習データを拡張しない

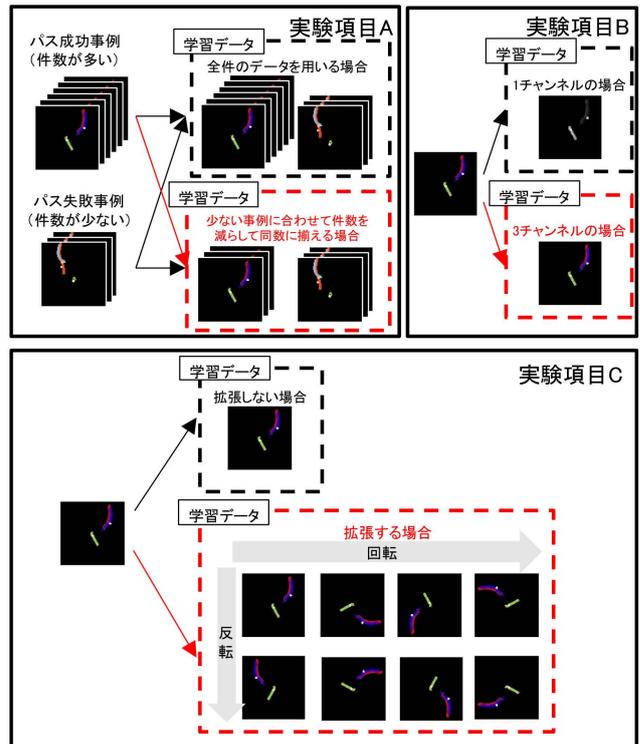


図5 実験項目ごとの実験データセットの作成方法

にサイドラインやエンドライン、ヤードラインとその数値、インバウンズラインなどが描画される。マッチアッププレーを分析する場合、QB、WRとDBの位置関係が重要であるため、プレーごとに異なるフィールド内の位置関係は無視できるものと考えられる。そのため、本研究で生成する画像は、プレーの司令塔であるQBを基点とした軌跡画像（図4）を用いる。一方、サイドラインやインバウンズラインなどはプレーごとに変わらない項目であるため、後述（4.3節）の実験にてその効果を確認する。

3.1.3 学習データセットの作成時の検討項目

本研究では、深層学習の適用によりマッチアップのプレー分析の実現可能性を検証するため、複数個のパターンのデータセットを作成して実験を行う。そして、データセットの作成方法がパス成否の推定精度に影響を及ぼすかを明らかにする。そこで、表3に示す3つの検討項目に沿ってデータセットを作成（図5）し、その精度を比較する。データセットの作成に関する検討項目を次に示す。

A) データ件数

アメリカンフットボールのプレーを日々計測する場合、正例と負例のデータが大量に蓄積される。これらのデータを全て分析に活用していくことを想定すると、正例と負例の件数の違いにより判定が偏る可能性がある。そこで、本項目（表3 実験項目 A）では、学習時において、正例の軌跡画像と負例の軌跡画像の件数の違いが精度に与える影響を確認する。実験では、実験データセットからテストデータを選別した後、残りのデータを全て学習に用いる場合と、正例および負例の件数を少ない方に合わせて同数に揃える場合の2通りを試行する。

B) チャンネル数

深層学習（ニューラルネットワーク）では、入力画像がカラー画像（3チャンネル）かグレースケール（1チャンネル）かにより、ニューラルネットワークの入力層のユニット数が異なる。本研究で用いる軌跡画像は、ポジションなどに応じて凡例を決めて着色している。そこで、本項目（表3 実験項目 B）では、深層学習で用いるデータのチャンネル数（色情報）が精度に与える影響を検討する。実験では、3チャンネル（RGBのフルカラー画像）と1チャンネル（グレースケール画像）の2通りを試行する。

C) 拡張の有無

深層学習は画像の特徴を自動で獲得するため、データ件数が多ければ多いほど良いことが知られている。そのため、データ件数が少ない場合、判定精度を向上させるためにデータを加工して拡張する方法が用いられる。一方、実際のプレーでは、横パスなどのプレーが存在し、そのパス方向は、回転または反転した前パスと類似することになる。このことから、回転や反転により拡張した学習データを利用した場合、他のプレーと誤認識することで精度が低下する可能性がある。そのため、本研究では、実験を通して本項目（表3 実験項目 C）の有用性を検証する。

実験では、学習データを拡張しない場合と、1件のデータに対して回転・反転により8倍に拡張した場合の2通りを試行し、学習データの拡張の有無が精度に与える影響を検討する。

3.1.4 軌跡画像の描画時の検討項目

本研究で生成する軌跡画像は、3.1.2項で詳述した通り、プレーの場所を表す情報や、プレーとは無関係の背景等を除外して描画している。しかし、パス成功率を判定する時、その精度は軌跡画像にどのような情報を描画したかにより異なる可能性がある。そのため、表4に示す軌跡画像の描画に関する実験項目を設定し、精度に影響する要因を検証する。各項目の具体的な描画例を図6に示す。本研究で試行する検討項目を次に示す。

i) 白線（ライン）の描画

サイドラインやインバウンズラインを描画した場合、フィールドの中央からプレーした時の左右への移動量を明示的に軌跡画像に表現できる。そこで、本項目（表4 実験項目 i）

表4 軌跡画像の描画に関する実験項目

実験項目番号	実験項目	実験条件	
		実験条件1	実験条件2
i	白線（ライン）の描画	描画しない	描画する
ii	軌跡の線幅	4px	8px
iii	パスタイミングの描画	描画する	描画しない
iv	軌跡のスケール	1.3倍に拡大	等倍（画像全体をフィールドと見なす）
v	軌跡の着色方法	所属チームとポジションごと	ポジションごと
vi	学習画像のサイズ	32px×32px	128px×128px

では、プレーの進行方向と並行なサイドラインとインバウンズラインの描画の有無を検討する。

ii) 軌跡の線幅

描画する選手の軌跡の幅（太さ）は、選手の動きを再現する上でも重要な要素である。例えば、線幅を細くすることで、選手の細かな動きを軌跡画像に表現することができる。そこで、本検討項目（表4 実験項目 ii）では、選手の移動軌跡の線幅を4px または8px のいずれかで描画するかを検討する。線幅は、検討項目 vi の画像サイズを小さくした場合、軌跡が消失することを加味して最小値を4px とした。

iii) パスタイミングの描画

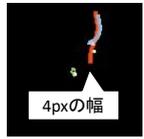
QB がパスした時点の各選手の位置の把握は成否に関わる重要な要素である。パスタイミングが画像に付与されていれば、パス時点の各選手の位置関係を加味できると考えられる。そこで、本検討項目（表4 実験項目 iii）では、QB がパスした時の各選手の位置に点を描画するかどうかを検討する。

iv) 軌跡のスケール

描画する軌跡のスケールは、画像全体に占める軌跡の割合が変化するため、無駄なスペースを無くす上で検討すべき項目の一つである。そこで、本検討項目（表4 実験項目 iv）では、軌跡の描画時に画像全体をフィールド全体と見なして描画（等倍）するか、拡大（1.3倍）するかを検討する。

v) 軌跡の着色方法

所属チームや能力に応じたポジションごとに選手を区別できるように着色する必要がある。例えば、ポジションごとに着色した場合、それらの動きの違いを表現できる。加えて、レギュラーメンバーかどうかの区別も行なった場合では、そのポジションの中でもプレーが上手い選手とそうでない選手を区別することができる。一方、着色時に加味する項目が多すぎるとデータのバリエーションが増え、その分、データ量が実質減少することで特徴を認識できなくなる弊害も想定される。そこで、本検討項目（表4 実験項目 v）では、各選手の軌跡の着色方法として、ポジションごとの着色に加えて、レギュラーチームのメンバーであるかどうかも含めて着色の方法を決定する。

項目内容	出力例	
白線(ライン)の描画	 ライン無し	 ライン有り
軌跡の線幅 (4px/8px)	 4pxの幅	 8pxの幅
パスタミングの描画	 パスタミングの点がある	 パスタミングの点がない
軌跡のスケール (1.3倍/1倍)	 1.3倍	 1倍
軌跡の着色方法 (所属チームと ポジションごと/ ポジションごと)	 所属チームと ポジションごとに着色	 ポジションごとに着色
学習画像のサイズ (32px×32px/ 128px×128px)	 32px × 32px	 128px × 128px(※)

(※)実際には4倍のサイズ

図6 描画に関する検討項目ごとの出力画像例

vi) 学習画像のサイズ

深層学習では、入力画像が一定のサイズである必要があることから、画像を入力する段階でサイズをリサイズして揃えることが一般的である。この時、サイズが小さければ学習に要する時間的コストを低減でき、大きければより多くの特徴を加味できる反面、時間がかかる。そこで、本検討項目(表4 実験項目 vi)では、深層学習に入力する画像を 32 px× 32 px、または 128 px× 128 px のいずれのサイズで学習するかを検討する。これにより、画像全体における軌跡が占める割合が変化するため、検討項目 iv とは違った軌跡画像のスパース性を考慮できる。

3.1.5 深層学習の実装方法

深層学習は、画像のカテゴリ判別をはじめ、画像認識や音声認識など幅広い分野で用いられる技術である。本研究では、深層学習の中でも、画像判別の分野で一定の成果を挙げている CNN を用いる。深層学習のフレームワークには、Chainer [20],

TensorFlow [21], Caffe [22] などがある。本研究では、2015 年に Google 社が公開している TensorFlow を用いる。TensorFlow の選定理由は、計算グラフの構築がベースとなっており、汎用性や拡張性に優れ、チュートリアルサンプルが数多く揃っていることによる。

本研究で用いる CNN は、画像を入力とし、パス成否を出力とするネットワークである。そのため、TensorFlow のチュートリアルで用意されている手書き数字画像の認識プログラム [21] を一部変更することで実装(図7)する。変更箇所は、入力層として、生成した画像のサイズとチャンネル数に合わせてユニット数を調整する点と、出力層として、パス成否に合わせて2ユニットにする点である。本研究では、図7に示すように、畳み込み層とプーリング層を2層、全結合層を繋ぎ、最終的にパス成功と失敗の2値を出力するネットワークを構築する。

3.2 学習の適用による目標精度

アメリカンフットボールの戦術分析では、1章にて紹介したように、軌跡によるプレーの識別や分類に留まっており、パス成否の推定には至っていない。そのため、本研究の提案手法を評価するために現場の経験に即した目標精度を設定する。

アメリカンフットボールのマッチアッププレーにおけるパス成否は、選手の巧拙や選手間の相性の他に、選手のコンディションやフィールドの状態、天候、気温、プレー時の日照条件など、様々な要因(表2の試合環境)が考えられる。そのため、パスプレーの成否は単純な成功と失敗の2通りに限らず、A) 確実に成功したパス、B) 失敗するはずが成功したパス、C) 成功するはずが失敗したパス、D) 確実に失敗したパスの4つに分類できると考えられる。現場の監督やコーチなど、アメリカンフットボール経験者へのヒアリングによると、感覚的には、A) と D) は、全体の6割程度であり、B) と C) は4割程度との意見が得られた。

一方で、実際のプレーの計測において、これらのデータを分類することは難しい。たとえば、B) と C) を人が判断する場合、感覚的に B) は失敗と判断し、C) は成功すると判断することに起因している。そのため、プレーの結果を反映した軌跡画像においても、A) と C) の軌跡は同じような特徴が見られ、B) と D) も同様の傾向があることが考えられる。これらの仮説に基づき、本研究における目標精度を試算した結果を表5に示す。これは、100回プレーを行った場合に、A) ~D) のプレーがどの程度発生するかを感覚的な意見に従って分類したものである。全体のデータ件数を100件、そのうちの正例を50件、負例を50件と仮定すると、A) ~D) の件数は表5のように試算できる。

深層学習によりこれらのデータに対してパス成否を判断する場合、A) と C) は成功、B) と D) は失敗と判断することが考えられ、この結果から適合率、再現率、F値を算出すると、表5の結果となる。したがって、本研究では、この試算結果に基づき、目標精度としてF値で0.600を目指して精度評価を行う。

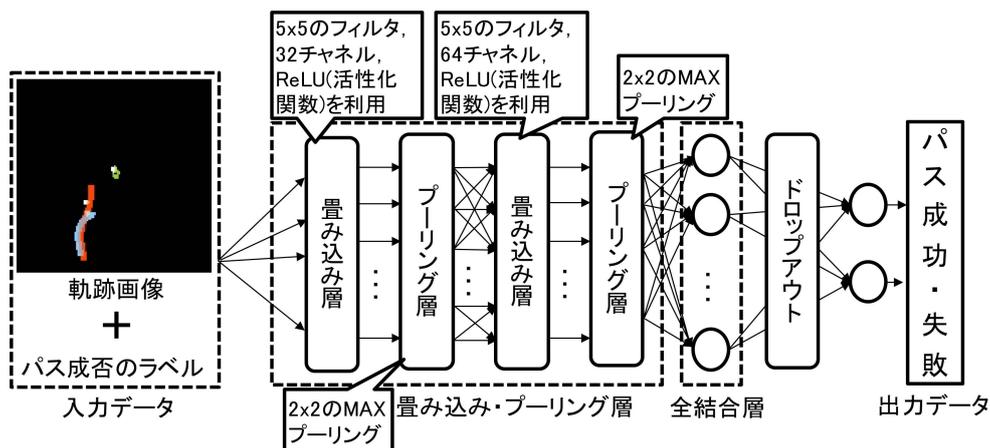


図7 CNNの構成

表5 深層学習の目標精度

実際のプレーの結果	機械的な判定の結果(件)		精度		
	正例と判定	負例と判定	適合率	再現率	F値
正例	30 (A)	20 (B)	0.600	0.600	0.600
負例	20 (C)	30 (D)	0.600	0.600	0.600

に示す実験項目 A~C の項目ごとにそれぞれ 2 通りの実験条件 (表 3 実験条件 1 および 2) を設定し、その精度を比較して最適な条件を見出す。そのために、各実験項目の実験条件 1 を基準値として、データセットを作成する。次に、実験項目 A~C を 1 項目ずつ実験条件 2 に従って変化させた学習データセットを作成する。最後に、それぞれのデータセットを用いて、学習モデルを生成し、パス成否の推定精度を確認する。その評価は、パス成功 (正例)、パス失敗 (負例) と全体の適合率、再現率と F 値により行う。

各データセットにおいて、テストデータは経験則に基づき全体の 1/4 と設定する。実験項目 A のデータ件数を揃えることを考慮して負例の件数 (28 件) の 1/4 とし、正例、負例ともに 7 件ずつとした。実験項目 A~C が全て実験条件 1 (基準値) のデータセットの場合、学習データが正例、負例ともに 168 件 (正例を負例と同数の 28 件に揃え、それぞれテストデータ 7 件を除いて 8 倍に拡張)、テストデータが正例、負例ともに 56 件 (元のテストデータ 7 件を 8 倍に拡張) である。

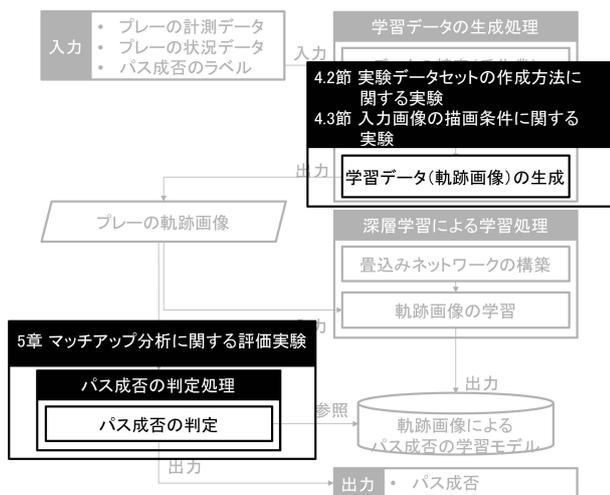


図8 実験計画

4. 深層学習の入力画像に関する検証実験

4.1 実験データの構成

本実験では、表 1 のパターン 2 の計測データ (計 68 件) を用いる。このデータには、正例が 40 件、負例が 28 件含まれている。本実験では、このデータを学習データと判定対象データに分割して用いる。実験項目に応じて、分割の仕方が異なることから、具体的な方法は後述 (4.2.1 項, 4.2.2 項) する。

4.2 学習データセットの作成方法に関する実験

4.2.1 実験概要

CNN の学習効果を向上させるため、最適な学習データセットの作成方法について検討する。具体的には、表 3 および図 5

4.2.2 実験手順

実験項目 A~C の各データセットの作成手順と実験手順を次に示す。

A) データ件数

本実験では、データ件数 (A) の違いによる影響を調査する。比較する実験条件は、全件を用いる場合と、正例と負例の件数を同数に揃える場合の 2 通りとし、その他の項目 (B と C) は基準値 (実験条件 1) とする。具体的な作成手順を次に示す。

STEP1 :

計測データセット 68 件を学習データ (正例 33 件, 負例 21 件) とテストデータ (正例, 負例とも 7 件) に分割する。

STEP2 :

STEP 1 のデータを回転・反転により拡張し、学習データ (正例 264 件, 負例 168 件) を CNN に入力し、学習モデル (以下、「全件モデル」) を構築する。

STEP3：

STEP 1 の正例の学習データから無作為に 21 件選定し，正例と負例を同数にする。

STEP4：

STEP 3 のデータを回転・反転により拡張し，学習データ（正例，負例とも 168 件）を CNN に入力し，学習モデル（以下，「同数モデル」）を構築する。

STEP5：

全件モデルと同数モデルを用いてテストデータを判定して結果を比較する。

B) チャンネル数

本実験では，チャンネル数（B）の違いによる影響を調査する。比較する実験条件は，グレースケール画像（1 チャンネル）を用いる場合と，フルカラー画像（RGB の 3 チャンネル）を用いる場合の 2 通りとし，その他（A と C）は基準値とする。具体的な作成手順を次に示す。

STEP1：

正例，負例ともに 28 件に揃えたデータセットの画像を全てグレースケールに変換する。

STEP2：

STEP 1 のデータセットと計測データセット（正例と負例で 56 件）の学習データ（42 件）とテストデータ（14 件）をそれぞれ回転・反転により拡張する。

STEP3：

STEP 1 のデータセットの学習データを CNN に入力し，学習モデル（以下，「グレースケールモデル」）を構築する。

STEP4：

計測データセットの学習データを CNN に入力し，学習モデル（以下，「RGB モデル」）を構築する。

STEP5：

グレースケールモデルを用いてグレースケールのテストデータを判定する。

STEP6：

RGB モデルを用いて計測データセットのテストデータを判定する。

STEP7：

STEP 6 と STEP 7 の判定結果を比較する。

C) 拡張の有無

本実験では，回転・反転による拡張の有無（C）の違いによる影響を調査する。比較する実験条件は，回転・反転を行わない学習データを用いる場合と，回転・反転を行う学習データを用いる場合の 2 通りとし，その他（A と B）は基準値とする。ただし，学習データ数は，拡張前の件数（正例，負例とも 21 件）とした。具体的な作成手順を次に示す。

STEP1：

正例，負例ともに 28 件に揃えた計測データセット（56 件）

表 6 学習データセットごとの精度結果

実験条件		基準値	①	②	③		
実験項目	A	同数	全件	同数	同数		
	B	3	3	1	3		
	C	有	有	有	無		
正例	学習データ件数		168	264	168	21	
	データ件数		56	56	56	56	
	判定結果	正例件数	40	18	15	40	
		負例件数	16	38	41	16	
	精度	適合率	0.656	0.529	0.319	0.519	
		再現率	0.714	0.321	0.268	0.714	
		F値	0.684	0.400	0.291	0.602	
	負例	学習データ件数		168	168	168	21
		データ件数		56	56	56	56
判定結果		正例件数	21	16	32	37	
		負例件数	35	40	24	19	
精度		適合率	0.686	0.513	0.369	0.543	
		再現率	0.625	0.714	0.429	0.339	
		F値	0.654	0.597	0.397	0.418	
全体		精度	適合率	0.671	0.521	0.344	0.531
			再現率	0.670	0.518	0.348	0.527
	F値		0.669	0.499	0.344	0.510	

の学習データ（42 件）を CNN に入力し，学習モデル（以下，「拡張前モデル」）を構築する。

STEP2：

STEP 1 の学習データ（42 件）を回転・反転によりそれぞれ 8 倍に拡張したデータセット（336 件）を作成する。

STEP3：

STEP 2 のデータセットの学習データを CNN に入力し，学習モデル（以下，「拡張後モデル」）を構築する。

STEP4：

拡張前モデルと拡張後モデルを用いて，回転・反転により 8 倍に拡張したテストデータを判定して結果を比較する。

4.2.3 実験結果と考察

実験結果を表 6 に示す。「基準値」の項目は全ての実験項目を実験条件 1 に設定した場合の結果であり，前項で述べた同数モデル，RGB モデル，拡張後モデルの結果である。また，①から③は 1 項目ずつ実験条件 2（表 3）に設定した場合の結果で，評価値が基準値を上回っている項目は網掛けで示している。これらから次のことが明らかとなった。

A) データ件数

学習データの件数の違いによる精度を比較（表 6 の基準値と①）すると，正例と負例の件数を同等とした場合の精度が向上する傾向が見られた。全件モデル（①）の負例の再現率は基準値よりも高い数値となっているが，他の数値に着目す

表7 出力画像ごとの精度結果

実験条件		基準値	①	②	③	④	⑤	⑥	
実験項目	条件A	同数							
	条件B	3							
	条件C	有							
	条件i	描画しない	描画する	描画しない	描画しない	描画しない	描画しない	描画しない	
	条件ii	4px	4px	8px	4px	4px	4px	4px	
	条件iii	描画する	描画する	描画する	描画しない	描画する	描画する	描画する	
	条件iv	1.3倍	1.3倍	1.3倍	1.3倍	等倍	1.3倍	1.3倍	
	条件v	所属チームと ポジションごと							
	条件vi	32px×32px	32px×32px	32px×32px	32px×32px	32px×32px	32px×32px	128px×128px	
正例	学習データ件数	168	168	168	168	168	168	168	
	データ件数	56	56	56	56	56	56	56	
	判定結果	正例件数	37	28	34	35	26	38	0
		負例件数	19	28	22	21	30	18	56
	精度	適合率	0.529	0.467	0.493	0.467	0.419	0.487	0.000
		再現率	0.661	0.500	0.607	0.625	0.464	0.679	0.000
		F値	0.587	0.483	0.544	0.534	0.411	0.567	0.000
負例	学習データ件数	168	168	168	168	168	168	168	
	データ件数	56	56	56	56	56	56	56	
	判定結果	正例件数	33	32	35	40	36	40	0
		負例件数	23	24	21	16	20	16	56
	精度	適合率	0.548	0.462	0.488	0.432	0.400	0.471	0.500
		再現率	0.411	0.429	0.375	0.286	0.357	0.286	1.000
		F値	0.469	0.444	0.424	0.344	0.377	0.356	0.667
全体	精度	適合率	0.538	0.464	0.491	0.450	0.410	0.479	0.250
		再現率	0.536	0.464	0.491	0.455	0.411	0.482	0.500
		F値	0.528	0.464	0.484	0.439	0.409	0.461	0.333

ると全体的に数値が下回っていることがわかる。このことから、学習データの件数を揃えることで、判定に偏りが生じる傾向を抑えることができると考えられる。

B) チャンネル数

チャンネル数の違いによる精度を比較（表6の基準値と②）すると、フルカラー画像（基準値）を用いる場合の精度が向上する傾向が見られた。グレースケールモデル（②）は、正例、負例ともにF値が0.4を下回る結果になっており、グレースケールのデータでは、学習が正常に行われていないことがわかった。このことから、チャンネル数を増加させてフルカラー画像とすることで、学習データに含まれる色情報を考慮でき、精度が向上すると考えられる。

C) 拡張の有無

回転・反転による拡張の有無による精度を比較（表6の基準値と③）すると、拡張前モデル（③）より拡張後モデル（基準値）の方が、精度が向上する傾向が見られた。このことから、回転や反転により拡張した学習データを用いた場合でも、方向が異なる他のプレーに影響されることがなく、データ件数の拡張手段として有効であることがわかった。これに

より、回転・反転によりデータ量を増加させることで、学習データの多様性が維持でき、精度が向上したと考えられる。

以上のことから、基準値を用いることにより、パスプレーのマッチアップにおいて、限定的であるが、成功及び失敗の推定（表6のF値0.669）の可能性を見出すことができた。

4.3 入力画像の描画条件に関する実験

4.3.1 実験概要

本実験では、軌跡画像の効率の良い描画方法を明らかにする。具体的には、表4および図6に示す6通りの方法でデータセットを作成し、それぞれの推定精度を比較する。本実験で用いるデータセットは、4.2節の結果に基づく方法で作成する。実験は、4.2節と同様、それぞれの実験条件を1項目ずつ変化させて行い、正例、負例と全体の適合率、再現率とF値で評価する。

4.3.2 実験手順

本実験では、表4の実験条件1（基準値）をベースに6つの実験項目i~viを1項目ずつ実験条件2に従って変化させた

データセットを作成し、各データセットの精度を比較して評価する。

4.3.3 実験結果と考察

本実験の結果を表7に示す。「基準値」の項目は4.2.3項と同様に、全ての実験項目を実験条件1に設定した場合の結果であり、①から⑥は1項目ずつ実験条件2に設定した場合の結果で、評価値が基準値を上回っている項目は網掛けで示している。これらから次のことが明らかとなった。

i) 白線の描画

白線の描画の有無による精度を比較（表7の基準値と①）すると、白線を描画しない方（実験条件1）の精度が良い傾向が見られた。理由としては、白線を描画した画像において、描画位置が固定の白線を軌跡と認識し、学習が正常にできていないことが考えられる。一方、負例の再現率を確認すると、白線を描画することにより、基準値のモデルと比較して1件多く負例を抽出している。しかし、その他の数値に着目すると全体的に数値が下回っていることから、全体的な精度向上を目指す場合、白線は描画すべきでないと言える。このことから、画像を作成する時には、白線などの静的な情報の描画を避けた方が良いことがわかった。

ii) 軌跡の線幅

軌跡を描画している線の太さによる精度を比較（表7の基準値と②）すると、太さが4pxの方（実験条件1）の精度が良い傾向が見られた。理由としては、8pxの太さで描画した画像において軌跡の線の大部分が重なり、大きな違いが見られず、誤認識が発生した可能性が考えられる。このことから、画像を作成する時に、各プレー軌跡の幅を短くすると、それぞれの違い（特徴）が明確になり、推定精度が向上できることがわかった。

iii) パスタイミングの描画

パスタイミングの点の有無による精度を比較（表7の基準値と③）すると、パスタイミングを描画した方（実験条件1）の精度が良い傾向が見られた。このことから、パスタイミングの描画は、パス成否に影響を及ぼす重要な特徴として捉えられている可能性があることがわかった。

iv) 軌跡のスケール

軌跡自体の大きさによる精度を比較（表7の基準値と④）すると、1.3倍に拡大した方（実験条件1）の精度が良い傾向が見られた。理由としては、無関係な背景面積が少なくなり、各プレー軌跡の違い（特徴）がより明確に認識できたと考えられる。このことから、画像を作成する時に、学習に使用する部分の面積が大きいほど、精度が向上する可能性があることがわかった。

v) 軌跡の着色方法

選手の着色方法による精度を比較（表7の基準値と⑤）す

ると、レギュラーチームの所属の有無に加えて、QB、WR、DBのポジションを考慮した色分けをした方（実験条件1）が、精度が良い傾向が見られた。これは、レギュラー陣とそれ以外の選手で比較しても、能力の違いから軌跡が異なる傾向があり、さらに、アメリカンフットボールではポジションごとに選手の役割や動き方も異なる点を考慮できたためと考えられる。このことから、所属チームやポジションごとの移動軌跡の違い（特徴）を学習できている可能性があることがわかった。

vi) 学習画像のサイズ

画像自体の大きさによる精度を比較（表7の基準値と⑥）すると、32pxの方（実験条件1）の精度が良い傾向が見られた。この実験条件2（表7の⑥）における負例の再現率を確認すると、1.000と実験条件1と比較して非常に高い値となっているが、正例を確認すると、全てを負例として判定している。これは、128pxの画像の場合では、32pxの時と比較して学習が正しく行われなかったためである。画像のサイズを大きくしたことで、無関係の背景面積が大幅に増加し、その中に描画されている軌跡を認識できなかったことが考えられる。

以上、基準値を用いることにより、パスプレーのマッチアップにおいて、成功及び失敗の推定（表7のF値0.528）ができることがわかった。

5. マッチアップ分析に関する評価実験

5.1 実験概要

著者らは、2章で詳述したように、GNSSにより計測した選手の位置情報を可視化することで、目視によりパスプレーの巧拙を分析した。そして、3章と4章にて深層学習を適用する方法について検討し、その実現可能性について実証した。さらに本章では、深層学習により機械的に判断したパスプレーの成否の要因について議論する。具体的には、2章で分析したプレーと、深層学習の判定結果とを照合し、それぞれのプレーが深層学習によりどのように判断されているかを考察する。これにより、アメリカンフットボールのパスプレーにおけるマッチアップ分析の可能性について追求する。

5.2 実験手順

本実験では、4章で示した基準値で作成した学習モデルによる推定結果が、2章の手作業によるマッチアップ分析と同様の傾向が得られているかを確認する。具体的な手順を次に示す。

STEP1 :

4章の基準に準じた軌跡画像のデータセットを生成する。

STEP2 :

2章で分析した軌跡の長さが異なる事例（短い事例と長い事例）と、マッチアップ時のWRとDBの距離が異なる事例（遠い事例と近い事例）の軌跡画像をそれぞれ1件ずつ目視によりピックアップする。

表 8 マッチアップ分析に関する実験結果

事例	対応する事例	判定結果
1	軌跡が短い事例 (正例)	7/8 (88%)
2	軌跡が長い事例 (負例)	4/8 (50%)
3	マッチアップ距離が遠い事例 (正例)	8/8 (100%)
4	マッチアップ距離が近い事例 (負例)	0/8 (0%)

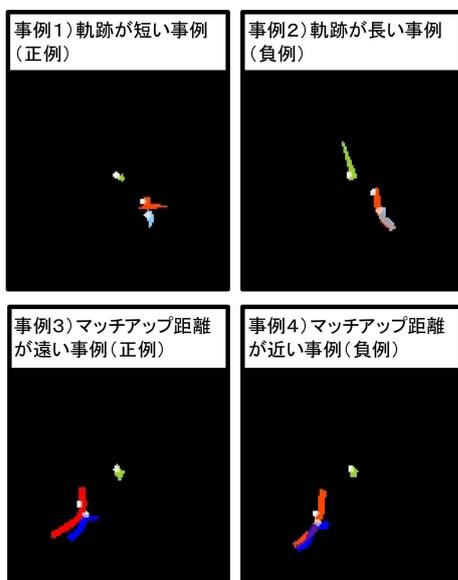


図 9 マッチアップ分析の軌跡画像

STEP3 :

STEP 2 のデータ以外の軌跡画像を全て学習データとして深層学習に入力し、学習モデルを構築する。

STEP4 :

STEP 2 の軌跡画像をテストデータとして、その判定結果を目視で確認して考察する。

5.3 結果と考察

実験結果を表 8 と図 9 に示す。表 8 の事例 1 と 2 は、2.3.4 項で分析した軌跡の長さが異なる事例であり、事例 3 と 4 は、マッチアップ時の WR と DB の距離が異なる事例である。表 8 の判定結果は、1 枚の軌跡画像を回転と反転により拡張して 8 倍に増やした画像の内、正しく判定できた件数とその正解率を示している。また、図 9 は、表 8 の各事例で判定した軌跡画像である。これらの軌跡画像および判定結果を目視で確認した結果、次のことがわかった。

- 軌跡の長さが異なるプレーの場合はマッチアップ分析ができる可能性がある

表 8 と図 9 の事例 1 と 2 を確認すると、判定結果に違いがあることがわかる。事例 1 プレーでは、8 倍に拡張した軌跡画像の内、7 つの軌跡画像を正しく推定しているのに対し、事例 2 のプレーでは、4 つの軌跡画像しか正しく推定できなかった。軌跡が短い正例 (図 9 の事例 1) では、2 章で分析したように、ボールを受け取る時に WR が QB の方を向いたために軌跡画

像が短くなる傾向がある。そのため、軌跡が短い画像は正例である場合が多く、深層学習においても表 8 の通り、多くの軌跡画像が正しく推定できた。一方、学習データ中の軌跡が短い負例を確認すると、QB と WR の距離が近い場合が多いことがわかった。この要因について、監督、コーチと選手へヒアリングを行った結果、パスをカットされないために球速が速いパスを行う場合があり、それによりボールのキャッチが難しくパス失敗となるケースがあることがわかった。

軌跡が長い負例 (事例 2) では、パスを行うまでに時間がかかったことにより、軌跡が長くなっている。学習データに含まれる他の負例を確認すると、軌跡が長い場合は、パスが失敗しているデータが多いことから、深層学習による判断においてもこれらの特徴を学習できているものと考えられる。

以上のことから、軌跡の長さが大きく異なるプレーの場合は、深層学習においても軌跡の長短によるパス成否の傾向を掴んでいる可能性が高く、マッチアップのプレー分析が可能であることがわかった。

- 選手間の距離を学習するには時系列を考慮する必要があることがわかった

表 8 の事例 3 と事例 4 を確認すると、全ての結果がパス成功と判断されていることが分かる。既存研究 [6] や 2 章の分析では、WR と DB の距離によってパス成否に違いがあることが確認できた。しかし、深層学習による判定では、これらの傾向の違いは見られず、全てのケースにおいて、パス成功と判断されている。この結果から、深層学習による判別では、選手間の距離の違いを考慮できていないと言える。この結果の要因を分析するため、実際の深層学習への入力データ (図 9 の事例 3 と 4) を確認すると、画像サイズを小さくしたことにより、選手間の距離の判別が困難な状態になっていると考えられる。そのため、選手間の距離を加味するためには、画像サイズの大小に関係なく選手間の距離を確認できる画像にする必要がある。

また、選手間の距離は、プレーの進行に応じて時々刻々と変化しており、監督やコーチ、選手もその時々々の位置関係に応じて瞬時に判断している。その特徴を深層学習で認識するためには、軌跡画像を時系列的に生成することが有効であると考えられる。そのため、今後の発展研究として、軌跡画像を時間単位に区切って生成し、段階に応じた学習モデルを生成する手法を検討する。この手法が実現すれば、任意時点の軌跡画像によりパス成否確率を推定できることから、プレー開始直後やプレー中における判断が可能となり、研究の最終目標の達成にも寄与できる。

以上のことから、現状の画像生成の手段では、選手間の距離が考慮されていないが、今後、時系列を考慮することでこれらの問題を解消できると考える。

6. おわりに

本研究では、アメリカンフットボールのパスプレーの軌跡画像に深層学習を適用することで、パス成功や失敗の特徴を明らかにすることができた。その結果、オフェンスとディフェンスのマッチアップ分析を可能にした。そして、プレーの成功率を

推定することで、戦術を再考するきっかけとなる新たな気づきを提供できる可能性があることを確認した。本研究成果は、次の利用場面で用いることができると考える。

- パスプレーの練習時において、レギュラーチームとそれ以外のチームの動きの比較や、プロ選手との動きの差異を詳細に確認し、プレーの問題点や改善点を分析できる。本手法は、蓄積したビッグデータから、深層学習により軌跡画像に内在する特徴を自動で獲得して、選手の能力の違いなども考慮できる。そのため、学校スポーツやプロスポーツなどの能力ごとに分ける必要がなく汎用的に利用できる。
- ミーティング時に、選手の移動軌跡や走行スピード、パスタミングなどを人為的に変更した軌跡画像を作成することで、どのようなプレーであればパスが成功するかのシミュレーションにも利用できる。

一方、検討すべき新たな課題も明らかになった。

- 現状ではバスプレーのマッチアップ分析のみに留まっており、ランプレーや、複数名の選手が出場する試合形式のプレーに対応できるかが明らかになっていない。これら全てのプレーに対応するには、膨大なプレーパターンのデータが不足している。この課題に対応するには、練習や試合の全ての多様多様なプレーを GNSS データだけでなく、ビデオカメラの映像を解析して選手を認識し、得られた位置情報から移動情報を取得する新たな方法が求められる。これが実現することで、大量の軌跡画像を蓄積したビッグデータから、パス成否に関わる根拠の抽出や、プレーの類型化による多角的なデータマイニング技術の確立が期待できる。
- 試合中の活用を想定すると、複数の WR とそれらに対応する DB とのマッチアップ状況を時系列に判断できれば、バスプレー中の成否を予測することができるが現段階では難しい。この要望に対応するには、軌跡画像を時系列で表現する手段の検討と、時系列を考慮できる RNN などのアルゴリズムの適用を試みる必要がある。この方法を組み込むことで、プレー結果の軌跡画像のみではなく、時事刻々と変化するプレーの状況を時系列的に判断でき、サイドラインから監督やコーチがプレー中の選手にタイムリーに指示するといった活用が期待できる。

以上、将来的にはこれらの技術を用いて、全選手を対象に試合中の戦術分析を目指す。さらに、サッカーやバスケットボールなどのセットプレーがある他のスポーツに適用して、研究成果の実用化を目指す。

謝辞

本研究を取りまとめるにあたり、関西大学先端科学技術推進機構社会空間情報科学研究センターに参画されている研究者および企業から多大なるご尽力を賜った。また、本研究の一部は、2018年度関西大学学術研究員研究費によって実施した。ここに記して感謝の意を表する。

参考文献

- [1] 文部科学省, スポーツ庁ホームページ: <http://www.mext.go.jp/sports/> [accessed Dec. 14, 2018]
- [2] 文部科学省, スポーツ基本法: http://www.mext.go.jp/a_menu/sports/kihonhou/ [accessed Dec. 14, 2018]
- [3] 文部科学省, スポーツ振興法: http://www.mext.go.jp/a_menu/sports/plan/06031014.htm [accessed Dec. 14, 2018]
- [4] M. Hayashi, T. Yamamoto, Y. Aoki, K. Ohshima, and M. Tanabiki: "Head and Upper Body Pose Estimation in Team Sport Videos," *2nd IAPR Asian Conf. on Pattern Recognition*, pp. 754-759, 2013.
- [5] S. Chen, A. Fern, and S. Todorovic: "Person Count Localization in Videos from Noisy Foreground and Detections," *Conf. on Computer Vision and Pattern Recognition*, pp. 1364-1372, 2015.
- [6] 藏野隼二, 山本大樹, 林昌希, 片岡裕雄, 青木義満: "スポーツ映像解析に向けたパス成功確率マップの作成," 映像情報メディア学会技術報告, Vol.37, No.36, pp. 45-48, 2013.
- [7] 藏野隼人, 林昌希, 山本大樹, 大島京子, 田藤雅基, 青木義満: "アメリカンフットボール映像におけるプレー開始・終了位置と選手動作情報を用いたボール軌跡抽出," 精密工学会誌, Vol.81, No.1, pp. 91-98, 2015.
- [8] 姜文淵, 山本雄平, 田中成典, 中村健二, 田中ちひろ: "単視点多眼によるアメリカンフットボールプレイヤーの識別と位置特定に関する研究," 写真測量とリモートセンシング, Vol.57, No.5, pp. 198-216, 2018.
- [9] フォアアシスト, GPS システム SPI HPU: http://4assist.co.jp/gpsports/gpsports_top2.html [accessed Dec. 14, 2018]
- [10] 山本雄平, 田中成典, 中村健二, 姜文淵, 田中ちひろ: "GPS による戦術分析のためのアメリカンフットボールの可視化システムの開発," ファジィシステムシンポジウム講演論文集, Vol.33, pp. 297-298, 2017.
- [11] 山本雄平, 田中成典, 姜文淵, 中村健二, 田中ちひろ, 清尾直輝: "アメリカンフットボールの可視化システムの開発および選手のプレー分析に関する研究," 情報処理学会論文誌, Vol.59, No.5, pp. 1334-1350, 2017.
- [12] 姜文淵, 山本雄平, 中村健二, 田中成典, 田中ちひろ, 政木英一, 山田貴之, 藤本雄一, 鳴尾丈司: "フィールドスポーツのための現場指向型可視化システムの研究開発," 情報処理学会論文誌, Vol.60, No.5, pp. 1212-1227, 2019.
- [13] J. Varadarajan, I. Atmosukarto, S. Ahuja, B. Ghanem, and N. Ahuja: "A Topic Model Approach to Represent and Classify American Football Plays," *British Machine Vision Conf.*, pp. 64.1-64.12, 2013.
- [14] E. Swears and A. Hoogs: "Learning and Recognizing Complex Multi-agent Activities with Applications to American Football Plays," *Workshop on the Applications of Computer Vision*, pp. 409-416, 2012.
- [15] R. Li and R. Chellappa: "Recognizing Offensive Strategies from Football Videos," *Int. Conf. on Image Processing*, pp. 4585-4588, 2010.
- [16] 谷俊廣, 黄宏軒, 川越恭二: "スポーツ競技戦略決定支援のための移動軌跡のマイニングと可視化システム," 第6回データ工学と情報マネジメントに関するフォーラム, E1-6, 2014.
- [17] I. Atmosukarto, B. Ghanem, S. Ahuja, K. Mutjuswamy, and N. Ahuja: "Automatic Recognition of Offensive Team Formation in American Football Plays," *Conf. on Computer Vision and Pattern Recognition Workshops*, pp. 991-998, 2013.
- [18] W. Kuan and R. Zemel: "Classifying NBA Offensive Plays Using Neural Networks," *Sports Analytics Conf.*, pp. 1-9, 2016.
- [19] 山田圭佑: "卓球ラリーロボット:一人と機械の融和を目指して一," 電気学会誌, Vol.137, No.2, pp. 81-84, 2017.
- [20] Preferred Networks, Chainer: <https://chainer.org/> [accessed Dec. 14, 2018]
- [21] Google, TensorFlow: <https://www.tensorflow.org/> [accessed Dec. 14, 2018]
- [22] Evan Shelhamer, Caffe: <http://imaginarynumber.net/> [accessed Dec. 14, 2018]

Dec. 14, 2018]

(2019年1月18日 受付)
(2019年7月4日 採録)

[問い合わせ先]

〒573-0196 大阪府枚方市北山 1-79-1
大阪工業大学情報科学部
山本 雄平
TEL: 072-866-5373
E-mail: yuhei.yamamoto@oit.ac.jp

—— 著 者 紹 介 ——



やまもと ゆうへい
山本 雄平 [正会員]

1986年生。2015年関西大学大学院総合情報学研究科総合情報学専攻博士課程後期課程修了。博士(情報学)。2015年、関西大学先端科学技術推進機構特別任命助教、2018年、同特別任命准教授、2019年から大阪工業大学情報科学部特任講師。Webマイニング、自然言語処理、スポーツ情報学に関する研究に従事。



たなか しげのり
田中 成典 [正会員]

1963年生。1988年関西大学大学院工学研究科土木工学専攻博士課程前期課程修了。博士(工学)。現在、関西大学総合情報学部教授及び関西大学先端科学技術推進機構社会空間情報科学研究センター長。2016年度科学技術分野の文部科学大臣表彰科学技術賞「科学技術振興部門」受賞。



なかむら けんじ
中村 健二 [正会員]

1981年生。2009年関西大学大学院総合情報学研究科総合情報学専攻博士課程後期課程修了。博士(情報学)。現在、大阪経済大学情報社会学部教授。2016年度科学技術分野の文部科学大臣表彰科学技術賞「科学技術振興部門」受賞。



たなか ちひろ [学生会員]

1993年生。2018年関西大学大学院総合情報学研究科知識情報学専攻博士課程前期課程修了。現在、関西大学大学院総合情報学研究科総合情報学専攻博士課程後期課程在学中。アメリカンフットボールのデータ計測、戦術分析に関連する研究に従事。



きょう ぶんえん
姜 文淵 [正会員]

1982年生。2017年関西大学大学院総合情報学研究科総合情報学専攻博士課程後期課程修了。博士(情報学)。現在、関西大学先端科学技術推進機構特別任命助教。MMSの点群データ、画像処理に関連する研究に従事。



はやし いさお
林 勲 [正会員]

1985年大阪府立大学大学院工学研究科経営工学専攻博士前期課程修了。工学博士。現在、関西大学総合情報学部教授。1997年南オーストラリア州立大学 KES 招聘研究員。1999年米国ボストン大学大学院 CNS 招聘研究員。2010年米国ボストン大学大学院 CNS 招聘教授。神経回路モデルを用いた視覚モデル、ファジィインタフェースによる脳とロボットとの相互結合モデル、動作解析とスポーツ戦略の研究に従事。

Research for Matchup Analysis of Pass Play in American Football with Deep Learning

by

Yuhei YAMAMOTO, Shigenori TANAKA, Kenji NAKAMURA, Chihiro TANAKA, Wenyuan JIANG, and Isao HAYASHI

Abstract:

In our country, policies regarding sports are actively advanced towards the Tokyo 2020 Olympic Games. One of those policies, "Sports x ICT" considers effective methods of utilizing ICT (Information and Communication Technology), such as development of measurement instruments, measurement and visualization of data, and proposals for new services in the field of sports. Against this backdrop, we have been developing the visualization system for American football games using terminal devices included GNSS and acceleration sensor. Using that system, we confirmed to grasp the effective information that are the individual condition and the motion analysis of American football players against not only players but also the college football leaders. But, in our existing research, we could not realize the strategy analysis of games that are to select the play calls depending on circumstances, to make a prediction of successful ratio, and so on. Then, in this research, we apply deep learning to the matchup analysis of pass play included offence and defense players, and then verify whether it is possible to infer the success or failure of a play from it.

Keywords: sports informatics, american football, pass play, matchup analysis, deep learning

Contact Address: Yuhei YAMAMOTO

Faculty of Information Science and Technology, Osaka Institute of Technology
1-79-1 Kitayama, Hirakata-shi, Osaka 573-0196, Japan
TEL: +81-72-866-5373
E-mail: yuhei.yamamoto@oit.ac.jp