原著論文

アメリカンフットボールのパスプレーの 移動履歴を考慮したマッチアップ分析に関する研究†

田中 ちひろ*¹・山本 雄平*²・姜 文淵*³・田中 成典*⁴・中村 健二*⁵・中島 伸介*⁶

スポーツ庁では、我が国の国際競技力の向上に関する重点政策において、日本代表選手の活躍を科学的側面から支援することを目指している。そこで、筆者らは、GNSS センサによるフィールドスポーツの可視化システムを開発してきた。特に、アメリカンフットボールに着目し、QB、WR、DB のマッチアップを対象にした軌跡画像を用いて、深層学習によるパス成否の判定を目指してきた。ただし、プレーが完了したトラッキング情報のみを用いているため、プレー中の成功率の予測や、その予測値に基づくタイムリーな動作の選択と修正をサイドラインから指示できるようなプレー中の気づき情報の獲得には至っていなかった。そこで、本研究では、軌跡の経時変化を加味したトラッキング情報を用いることで、プレー中の成功率を予測することを試みる。実験では、クイックパス、ショートパスやロングパスなどの軌跡を対象に分析を行い、その有用性を実証した。

キーワード：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、時系列解析

1. はじめに

我が国では、東京オリンピックをはじめ、ラグビーワールドカップや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に備え、スポーツ振興法 [1] の全面改定など、スポーツに関わる政策が推し進められている。特に平成 27 年に設置されたスポーツ庁 [2] は、日本代表選手の活躍を期待し、重点政策 [3] として「我が国の国際競技力の向上」を推進している。これらの政策を受けて、選手の競技水準の向上を目的としたスポーツ分野における ICT の応用に関する研究が盛んに行われている。

既存研究では、動画の解析や GNSS (Global Navigation Satellite System) などの各種センサによる計測によって、選手 [4–6] とボール [7] をトラッキングし、プレーの分類・認識 [8–11]、またはフォーメーション分析 [12] などを行っている。これら

の研究は、最終的に、戦術分析 [13] への応用を目指すものである。ただし、既存研究 [13] では、選手のトラッキング結果（軌跡）を利用した戦術分析の可能性を示しているが、定量化した数値による分析には至っていない。

そこで、著者らは、アメリカンフットボールに着目し、開発したプレーの可視化システム [14] を利用して、ポジションごとの選手の移動軌跡とバスタイミングを考慮したマッチアッププレーの分析や戦術分析による勝率の定量化 [15] を試みてきた。アメリカンフットボールは、数 100 種類のプレーで戦術が組み立てられ、適宜な作戦の選択が試合の勝率に影響するスポーツである。そのため、戦術の分析には、選手の位置関係やパスルートなど様々な要因を総合的に考慮する必要がある。正確な分析が困難な課題がある。

この課題を解決するため、著者らは深層学習に着目した。深層学習は大量のデータを学習することにより、自動的にデータの特徴を取得することができる。そのため、深層学習を用いて、戦術分析に関わる重要な情報を自動的に獲得することを試みる。著者らは、オフェンスとディフェンスのマッチアップの結果を対象とし、既存システム [14, 15] により可視化された選手の軌跡情報に深層学習を適用 [13] した。その結果、入力した選手のプレー中の軌跡とバスタイミングから、パス成功率を算出できることがわかった。選手の動きからパス成功率がわかれば、適切な戦術立案が可能となる。しかし、これまでの取り組みでは、プレー終了後の軌跡からパス成功率を算出しているため、プレー中にパス成否を提示するといった活用ができず、実戦形式での戦術分析へ適用することが難しい。このことから、試合の勝率を上げるには、プレー中の状況に応じたパス成否を提示できることが望ましい。

そこで、本研究では、深層学習により選手の軌跡情報の時系列的な変化を考慮して、プレー中のパス成功率の予測を試みる。これにより、試合中にリアルタイムな戦術分析が可能となり、試合を有利に導くことができると考えられる。最終的に、

† Research for Pass Matchup Analysis Considering Movement Records in American Football
Chihiro TANAKA, Yuhei YAMAMOTO, Wenyan JIANG, Shigenori TANAKA, Kenji NAKAMURA, and Shinsuke NAKAJIMA
*1 関西大学大学院総合情報学研究科
Graduate School of Informatics, Kansai University
*2 大阪工業大学情報科学部
Faculty of Information Science and Technology,
Osaka Institute of Technology
*3 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
*4 関西大学総合情報学部
Faculty of Informatics, Kansai University
*5 大阪経済大学情報社会学部
Faculty of Information Technology and Social Sciences,
Osaka University of Economics
*6 京都産業大学情報理工学部
Faculty of Information Science and Engineering,
Kyoto Sangyo University

図1 アメリカンフットボールのポジション

指導者のみならず、選手に対して実戦レベルの有益な情報を提供することを本研究の目的とする。

2. 戦術分析の方針と研究目的

2.1 戦術分析の現状

現状では、選手自身のパフォーマンスの向上やチームの戦術の確認を目的として、ビデオカメラで撮影した映像を用いた分析が行われている。この分析では、監督やコーチ、選手が映像を目視で確認し、選手の走行コースやフォーメーションなどのプレーの是非を検証している。このような分析手法は、社会人チーム、学生チームに限らず取り入れられている。その背景としては、スポーツ分野で映像を管理・共有するためのソフトウェア [16] の台頭がある。

一方、映像による分析は、監督やコーチ、選手などの主観的な分析となることから、選手の速度や距離といった定量的な数値データを用いる方法が一般的である。数値データの計測には、GNSS等の各種センサを選手に装着して計測する方法 [14, 15] や、映像を解析して選手の位置情報などを得る方法 [17] がある。しかし、いずれの場合においても、データを活用すること自体が過渡期であり、標準的な分析方法が未だ確立されていないのが現状である。

2.2 パスプレーの戦術分析方針

アメリカンフットボールのオフェンス (OF) とディフェンス (DF) の一般的なポジションを図1に示す。アメリカンフットボールのパスプレーの練習形態はスクリーメージ、パススケルトン、マッチアップの3種類が挙げられる。スクリーメージとは、OF11人、DF11人の実戦を想定した試合形式の練習形態のことで、パススケルトンはオフェンスライン (OL) やディフェンスライン (DL) がいないパスプレーの練習形態のこと、そして、マッチアップはワイドレシーバー (WR) とディフェンスバック (DB) の1対1のマンツーマンの練習形態のことで

図2 研究の目標

ある。著者らは、データを活用した戦術解析の方法を確立するため、スクリーメージから、プレー分析および戦術分析を行うことを目指してきた。その中でもランプレーにおいては、ボールの行方を追うことが難しい上、攻守の境目であるスクリーメージラインを超えた後は個人の技量に大きく依存するため、パスプレーに限定している。著者らが目標としている戦術分析は、図2に示すように、数秒後のWRの捕球位置やディフェンスの位置からパス成功率を予測し、エリアごとの成功率を監督・コーチに情報提供することである。これにより、リアルタイムにクォータバック (QB) に適切な指示を出すことができると考える。既存研究 [13] では、その前段階として、試合形式のスクリーメージではなく、比較的解析が容易な練習時のパスプレーのスケルトンの分析を行ってきた。

バスケットン分析において、アメリカンフットボール部の指導者が定量的に求めている情報は次の3つである。

1. パスパターンごとのオフェンスの司令塔であるQBが投げるポイントとタイミング、ターゲットとなる捕球者のWR、ラインとパスの両方を器用にこなすタイトエンド (TE) やラン専門であるが時にはショートパスにも対応するランニングバック (RB) のコース取りとスピード
2. パスカバーごとのレシーバーに対するオフェンスのランやパスプレーを阻止するラインバッカー (LB) とパスプレーに対応するDBの動きを時系列でマッピングすることと、同時に、LBとDBのカバーすべきエリア
3. リリース時のQBのパス判断の基準、リリース時のWRとDBの動きの変化点、リリース後のプレーの最終結果

これらの情報の内、オフェンスの要であるQBの投球に関する情報は特に重要である。QBは、WRの個人能力を加味した

がら、WR と DB の位置関係に重点を置き、パスをするかどうか、またそのタイミングを瞬時に判断している。そのため、WR と DB の組み合わせによるそれぞれのプレー能力やパスを行うまでの WR と DB の位置関係、さらに位置情報に基づくパス成功時と失敗時のコース取りの比較などの解析が有用であると考えられる。

しかし、バススケルトンの詳細な分析を行う前に、選手一人ひとりの巧拙の把握や、QB、WR と DB のマッチアップ分析の実現可能性を検証する必要がある。そこで、著者らは、スクリーンイメージの分析を長期目標として掲げ、中期目標にバススケルトン、短期目標にバスプレーのマッチアップ分析を設定して戦術分析を目指してきた。

2.3 研究過程と研究目的

筆者らは、これまで、GNSS センサを用いて複数選手を可視化するシステムを開発 [14] し、計測データからの統計的な分析と、可視化システムを用いて短期目標のバスプレーのマッチアップ分析 [15] を行い、選手の巧拙や動きの特徴などを確認した。また、QB、WR、DB のマッチアップを対象に GNSS センサからバスプレーのデータを取得し、深層学習を用いて軌跡画像からパス成否の判定 [13] を機械的に行った。その結果、軌跡の長さや軌跡の距離間からパス成否の傾向を掴むことができた。

しかし、これまでの研究 [13] では、プレーが完結したトラッキング情報のみを用いているため、プレー中のタイムリーな情報の獲得には至っていない。そのため、リリース前の QB の適宜な判断による動きの変化や、WR の臨機応変な動作と DB のカバーすべきエリアの瞬時の反応などを考慮しておらず、プレー中の時系列の情報から読み取れる新たな気づきを定量的に提示できていない。これが実現することで、練習中の選手の動きの是非を指摘し、改善点をアドバイスすることや、プレー中のタイムリーな指示と戦術立案が可能となる。

そこで、本研究では、アメリカンフットボールにおけるバスプレーのマッチアップ分析に関する研究 [13] を発展させて、プレーが完結したトラッキング情報のみを取り扱うだけでなく、経時変化の情報（移動履歴）を用いることで、プレー中の成功率の予測を試みる。これにより、その結果を基に、プレー中の良し悪しや、動作の修正をサイドラインから大声で叫びながらアドバイスすることができる。最終的に、指導者のみならず、選手に対して実戦レベルの有益な情報を提供することを目的とする。

また、本研究では、クイックパス、ショートパスやロングパスなどの全種類のバスプレーを対象とし分析する。クイックパスは 5 ヤード（1 ヤードは約 0.91 メートル）までの短いプレー、ショートパスは 10 ヤードの獲得を目指したプレー、ロングパスは 10 ヤード以上の大きな前進を試みるプレーである。

3. 移動履歴を考慮した戦術分析の検討

3.1 移動履歴を考慮した戦術分析の構想

アメリカンフットボールでは、試合中の状況に応じて、リアルタイムに適切な戦術を立てることが重要である。特に、監督

やコーチに最善のプレー選択ができる環境を提供できれば、プレーの開始時や進行中に、適切な予測データを提示することが可能となる。そこで、本研究では、選手の軌跡の経時変化に着目し、プレー画像の特徴を自動的に識別できる深層学習を活用して時々刻々と変化するパス成否の推定を試みる。

既存研究 [13] では、プレー開始時から終了時までの移動軌跡を可視化した画像データを用いて、学習と推定を行っている。しかし、全体の軌跡を使用した場合、一定時間ごとのパス成否の予測ができない。そのため、本研究では、一定時間ごとの軌跡画像を作成し、それを学習したモデルを利用して、パス成否を推定する。

また、アメリカンフットボールでは、選手ごとに多種多様なプレーが存在し、それぞれのプレーの特徴も異なる。しかし、既存研究 [13] では、これらのプレーごとの特徴を考慮せず、全てのプレーから 1 つの学習モデルを生成している。その結果、推定精度の低下や精度が不安定となる現象が見られた。そこで、本研究では、プレー開始時点において、選手が取るべきプレーが予め戦術として決められていることに着目し、プレー名を考慮した学習を行うことで課題の解消を試みる。

3.2 チームプレーの分析の検討項目

本研究では、3.1 節の構想の有用性を検証するため、プレー名と時系列の移動履歴を考慮することで推定精度に変化が見られるかを確認する。

プレーは、種類ごとに名前があり、それぞれの特徴も異なっている。そのため、プレー名ごとに軌跡データを分類して学習することで、プレー名に応じた特徴を獲得することが可能であると考えられる。このことから、まず、軌跡データをプレーの種類ごとに分類し、プレー名を考慮した学習と推定を行うことで推定精度の変化を検証する。アメリカンフットボールでは、選手個々人のポジションも数種類あり、WR のプレー開始時のフィールドの左右の位置や、プレー開始後の走行方向などによりさらに細かく分類されている。しかし、プレー分類ごとの学習モデルを構築する場合、細分化するほど 1 モデルあたりの学習データ量が減少する。そのため、本研究では、プレー開始時の QB に対する WR の位置（左右）と、プレー開始後の WR の走行方向（左右）の 2 パターンで大別して分類することを検討する。そして、経時変化に応じたパス成功率・失敗率を提示できるかを検証する。具体的には、プレー開始時を基準とした 1 秒ごとの経過秒数に応じた軌跡画像（0～1 秒の軌跡画像，0～2 秒の軌跡画像，…，0～n 秒の軌跡画像）を生成する。そして、プレーの進行に応じた秒数毎に、その時点でのパス成功率・失敗率の変化を確認する。これにより、移動履歴を考慮したマッチアップ分析の有用性を評価する。

3.2.1 深層学習のネットワーク構成

本研究では、TensorFlow を用いて、軌跡画像を学習する畳み込みニューラルネットワーク（CNN）を実装する。TensorFlow は、2015 年に Google 社が公開した計算グラフを用いた数値計算用のオープンソースライブラリであり多用されている。CNN は、画像を入力することで、特徴を自動的に識別し、画

図3 CNNの構成

表1 各データセットのプレー件数

分類		成功(件)	失敗(件)
データセットA	分類なし	36	46
	開始位置(左)	15	11
データセットB	開始位置(右)	21	35
	開始位置(左)	13	8
データセットC	開始位置(左) 走行方向(左)	2	3
	開始位置(右) 走行方向(左)	3	11
	開始位置(右) 走行方向(右)	18	24
	開始位置(左) 走行方向(右)		

表2 データセットの条件

条件項目	設定値
データ件数	正例/負例の内少ない方の件数に合わせて同数に揃える
チャンネル数	RGBの3チャンネル(カラー画像)
拡張の有無	「90度ずつの回転のみで拡張」, 「反転後に90度ずつ回転したデータを学習データに追加して拡張」
白線の描画	描画しない
軌跡の線幅	4px
パスタイミングの描画	描画する
軌跡のスケール	1.3倍に拡大
軌跡の着色方法	ポジションごとの色分けに加えてレギュラーチーム所属の有無を考慮して着色
学習画像のサイズ	縦・横ともに32px

像分類などを行うことが可能である。本研究では、CNNに軌跡画像を入力し、分類結果としてパス成否を推定する。

本研究で用いるCNNの構成は、既存研究[13]と同様に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[18]を一部変更したものを用いる。本研究で実装したネットワークを図3に示す。変更箇所は、入力層を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、出力層をパス成否に合わせて2ユニットとする点である。最終的に、パス成否の成功率と失敗率を出力する。

3.2.2 実験条件の選定

本研究では、プレーの種類としてWRのプレー開始位置(左右)とWRの走行方向(左右)を考慮して学習する。既存研究[13]で用いた回転・反転によるデータ拡張を行う場合、反転により開始位置と走行方向の左右が逆転し、事実と異なるプレーの軌跡画像が生成される。そのため、本研究では、回転のみの拡張と、反転も含めた拡張のそれぞれの場合における精度を検証する。

本研究で使用する各データセットのプレー件数を表1に示す。データセットAは、すべてのプレーが包括されている。データセットBは、データセットAの内、QBからみたWRの開始位置の左右により分類している。データセットCは、データセットBから、さらにWRの走行方向の左右により分類したものである。

図4 チームごとの軌跡の配色例

本研究で使用するデータセットは、既存研究[13]で明らかになった学習条件(表2)に準じて作成する。設定した軌跡画像の配色例を図4に示す。QB、WR、DBのポジションごとにレギュラーチーム(Aチーム)とそれ以外のチーム(Bチーム)で色分けしている。詳細を以下に示す。

- ・レギュラーチーム：QB(黄), WR(赤), DB(青)
- ・それ以外のチーム：QB(黄緑), WR(ピンク), DB(緑)

図5 データセットの分類方法

また、軌跡画像内に描画されている白の点は、QB がパスをしたタイミングを示している。

4. 深層学習による戦術分析の検討

4.1 プレー分類を考慮した戦術分析の検証

4.1.1 実験の概要

本実験では、プレー分類を考慮した軌跡画像によるパスプレーのマッチアップ分析の有効性を確認する。そこで、プレーの種類ごとにパス成功率と失敗率の推定精度を検証する。また、各データセットの学習データを回転により4倍に拡張するケース（以下、回転データ）と、回転・反転により8倍に拡張するケース（以下、回転・反転データ）の違いについても検討する。評価は、パス成功（以下、正例）、パス失敗（以下、負例）、全体の適合率、再現率とF値により行う。

4.1.2 プレー分類による学習データセットの詳細

本実験では、プレー分類を考慮したパス成功率と失敗率の推定精度を検証する。分類の有無による違いの検証では、分類の粒度が異なるデータセットA、B、C（図5）を用いる。そして、データセットA、B、Cのそれぞれに対して、回転データのみ、または回転・反転データからなる合計6通りのデータセットを作成する。各データセットの件数を表3、データセットの分類方法を図5、拡張方法を図6に示す。詳細な作成手順は次の通りである。

A) データセットAは、既存研究[13]と同様に全てのプレーの軌跡画像を用いて作成する。これは、プレー分類の情報を入力データに加味していないことと同義である。既存研究[13]に従い、回転前の計測データの正例と負例の件数をランダムサンプリングによって同数に揃え、約1/4をテストデータ、約3/4を学習データとする。そして、回転、または回転・反転により、回転データ（以下、回転のデータセットA）と回転・反転データ（以下、回転・反転のデータ

図6 データセットの拡張方法

表3 各データセットの件数の詳細

		学習データ（件）			テストデータ（件）		
		成功	失敗	合計	成功	失敗	合計
回転	データセットA	108	108	216	36	36	72
	データセットB	64	64	128	20	20	40
	データセットC	52	52	104	20	20	40
回転・反転	データセットA	252	252	504	36	36	72
	データセットB	108	108	216	20	20	40
	データセットC	84	84	168	20	20	40

タセットA)に拡張する。

B) データセットBは、Aの内、QBを基点としたWRのプレー開始地点（左右）で分類した軌跡画像から作成する。Bでは、開始地点による左右2通りの分類結果に基づき、データ件数の多い方を選択する。Aと同様に正例と負例の件数を揃え、テストデータと学習データに分割する。そして、回転、または回転・反転により、回転データ（以下、回転のデータセットB）と回転・反転データ（以下、回転・反転のデータセットB）に拡張する。回転・反転のデータセットBは、反転により開始位置の左右が逆転する。そのため、反転したデータは反転後の開始位置の左右に従って分類する。

C) データセットCは、BのデータからWRの走行方向（左右）に応じてさらに細分化した軌跡画像から作成する。Cでは、Bと同様に開始地点および走行方向による4通りの分類結果から件数が最多のものを選択し、A、Bと同様に正例と負例の件数を揃えて、テストデータと学習データに分割する。そして、回転、または回転・反転により、回転データ（以下、回転のデータセットC）と回転・反転データ（以下、回転・反転のデータセットC）に拡張する。回転・反転のデータセットCは、回転・反転のデータセットBと同様に反転によって左右が逆転するため、反転後の開始位置と走行方向のそれぞれの左右に従って分類する。

以上の手順にて作成した6通りのデータセットは、交差検証

を行うため、表3に示す件数に従ってテストデータと学習データに振り分ける。そして、軌跡画像を変更して、全て10セットずつ（合計60セット）用意する。精度を比較することを考慮して、データセットAの回転と、データセットAの回転・反転における10セットそれぞれのテストデータは同じ軌跡画像を選定した。これは、BおよびCも同様である。また、表3の各データセットのテストデータの件数は、正例と負例の件数を揃えるため、表1の各データセットの内、件数の少ない正例に合わせて、その約1/4の件数とした。データセットAでは、正例・負例ともに9件ずつ、BとCは5件ずつ抽出し、それらを回転させて4倍の件数に拡張して表3に示す件数とした。

4.1.3 実験の手順

本実験で用いるデータセットの学習と推定の実験手順を次に示す。

STEP1：

前項で作成した各データセットを用いて、CNNにより3,000回学習したモデルを作成する。

STEP2：

それぞれのデータセットの学習モデルを用いて、対応するテストデータのパス成否の推定を行う。

STEP3：

STEP1～2の手順を各データセットで10回ずつ試行し、データセットごとにパス成功率と失敗率を集計して最終結果を導出する。

そして、回転のみと、回転・反転したデータを用いたパス成功率・失敗率の違いを確認する。

4.1.4 結果と考察

本実験の結果を表4に示す。表4は、4.1.3項の手順に従って作成したデータセットA、B、Cの回転および回転・反転した場合の精度を表す。また、本実験の比較対象として、回転・反転のデータセットAと同様の方法で作成した既存研究[13]の精度も併記する。ただし、回転・反転のデータセットAと既存研究[13]では、元の計測データの件数が異なる。

・反転によるデータの拡張が有効であることがわかった

表4から、データセットA、Cの回転と回転・反転を比較すると、回転・反転によりデータを拡張した方が精度の向上が見られる。また、回転のデータセットAと既存研究[13]の比較からも、回転・反転のデータセットAの方法で作成している既存研究の方が良い結果が得られた。データセットBにおいても、反転によるデータの拡張で精度の向上は見られなかったものの、回転のデータセットBとの差は0.018ポイント（全体精度F値）と僅差であることから、反転により学習データを拡張することは有効であると考えられる。

このことから、深層学習によるパス成否の推定には、効率的にデータを増やす手段が必要であり、反転による拡張はその一手段として活用できることがわかった。

表4 各データセットの実験結果

データセットの種類		回転			回転・反転			既存研究
		A	B	C	A	B	C	
正例	データ件数	36	20	20	36	20	20	56
	判定結果							
	正例件数	20.3	13.2	9.6	22.4	12.3	10.1	37
	負例件数	15.5	6.8	10.3	13.5	7.6	9.9	19
	適合率	0.478	0.535	0.469	0.656	0.532	0.489	0.529
	再現率	0.564	0.659	0.479	0.624	0.616	0.507	0.661
負例	F値	0.506	0.584	0.462	0.628	0.560	0.486	0.587
	データ件数	36	20	20	36	20	20	56
	判定結果							
	正例件数	21.9	11.1	11.0	12.4	11.4	10.6	33
	負例件数	14.2	8.9	9.0	23.7	8.7	9.4	23
	適合率	0.479	0.613	0.455	0.648	0.578	0.489	0.548
全体精度(平均)	再現率	0.393	0.447	0.449	0.657	0.437	0.470	0.411
	F値	0.412	0.497	0.439	0.641	0.484	0.465	0.469
	適合率	0.479	0.574	0.462	0.652	0.555	0.489	0.538
	再現率	0.479	0.553	0.464	0.641	0.526	0.488	0.536
	F値	0.479	0.540	0.450	0.635	0.522	0.476	0.528

・プレー分類を考慮することで安定した精度で推定できることがわかった

表4から、データセットBとCは、回転、回転・反転ともに同程度の精度で推定ができていることに対して、データセットAは、回転と回転・反転で大きな差が見られる。これは、データセットAがプレーを分類していないため、データの良し悪しやデータ量に左右されて推定結果が変化する傾向があることを示している。一方で、データセットBとCは、QBの位置に対するWRの開始位置や走行方向に応じて分類されているため、データに一貫性があり、データの善し悪しに左右され難しく安定した推定精度を保持していることがわかった。

・分類することで学習データが少ない場合でもパス成否を推定できる可能性があることがわかった

表4を確認すると、回転・反転のデータセットAの精度が最も高い結果となった。表3のデータセットの件数から、この学習データは504件であり、他のデータセットと比較して2倍以上の件数を有していることから、学習データの多さが精度に影響していることが考えられる。一方、回転・反転のデータセットBでは、学習データの件数が半数以下と少ないにもかかわらず、同件数の回転のデータセットAと比較して、F値が大きく向上している。このことから、プレー分類を考慮することで、効率的にデータを学習できることがわかった。

また、データセットCの結果を確認すると、推定精度がAやBと比較して低い値となった。これを踏まえて、データセットBとCのエポックの学習状況（図7）を確認すると、学習回数が3,000回の時点で、Train Accuracyが1に達していることから、学習が十分であることがわかった。したがって、データセットCの精度が低い原因は、細分化したことにより学習データの件数が減少したことによるものと考えられる。データセットCに関する学習状況（図7のTest Accuracy）を確認すると、その精度はデータセットBのTrain Accuracyと比較して変動

図7 データセット B と C の学習状況

が大きいことがわかる。このことから、プレーの分類を過度に細分化すると、判定精度が大きく変動することが考えられる。

以上のことから、プレーの分類から学習データの質を向上でき、データ数が少ない場合でも分類する前と同程度の精度でパス成否を推定可能であると考えられる。

アメリカンフットボールは、パスプレーだけでも数十パターンある競技であるため、実用化を考えた場合、全てのパターンを計測し、解析するまでのデータを集めることはかなりの時間と労力が必要となる。この点を考慮すると、QB から見た時の WR の開始位置による分類が最適であるという望ましい結果が得られたと言える。この結果から、回転・反転のデータセット B を使用して以降の実験を実施する。

4.2 移動履歴を考慮した戦術分析の検証

4.2.1 実験の概要

本実験では、プレーの進行中にパス成否を推定することで、移動履歴を考慮したパスプレーのマッチアップ分析の有用性を検証する。パスプレーの状況は時々刻々と変化することから、移動履歴を考慮することで、プレーの経時変化に伴ってパス成否も変化することが予想される。そのため、本実験では、経時変化におけるパス成功率と失敗率の変化を確認する。本実験では、前節の実験において明らかとなったプレーの分類も同時に考慮する。

4.2.2 移動履歴のデータセットの詳細

本実験では、移動履歴を考慮するため、プレーの秒数に応じた軌跡画像を生成する。全データを目視で確認した結果、全てのプレーが 8 秒以内に終了していることがわかった。そのため、本実験では、4.1.2 節の回転・反転のデータセット B を用いて、プレーの経過秒数を 1 秒ごとに区切った軌跡画像を生成する。具体的には、回転・反転のデータセット B を用いて、0～1 秒、0～2 秒のように 1 秒区切りで 8 秒までの時系列の軌跡画像を生成し、同様の方法で 10 件全てを時系列データに変更する。これにより、秒数ごとに 10 セットずつ、合計 80 セットのデータセットを作成する。表 5 に示す各データセットの件数は、表 3 の回転・反転のデータセット B と同様である。

4.2.3 実験の手順

本実験の手順を次に示す。

STEP1：

前項で作成した回転・反転のデータセット B の時系列データのそれぞれに対して、CNN により 3,000 回学習したモデルを作成する。

STEP2：

STEP1 の学習モデルを用いて、学習データに対応するテストデータを用いて、パス成否の推定を行う。

STEP3：

STEP1～2 の手順を各データセット 10 回ずつ試行し、データセットごとに適合率、再現率と F 値を算出し、10 回分を集計して平均精度を求める。

STEP4：

STEP3 で求めた精度から、秒数ごとのデータセット 10 件分を集計して平均精度を求める。

4.2.4 結果と考察

本実験の結果を表 5 と図 8、図 9 に示す。プレーの経時変化に伴ってパス成否も変化するという仮説を基に検証した結果から、以下のことがわかった。

- プレー初期段階の軌跡画像からパス成否を判定できることがわかった

表 5 における 1 秒と 2 秒の全体の F 値に着目すると、1 秒時点では 0.568、2 秒時点では 0.557 であり、経時変化が少ない場合でも前節の実験結果と同程度以上の精度で判定できていることがわかった。これは、深層学習により、プレー開始時点における選手の位置や移動軌跡から、成功と失敗に関する微細な特徴を捉えることができたためと考えられる。この特徴の例を図 8 に示す。初期段階の成功の軌跡画像の特徴は、DB が WR の動きを見ているため、初期位置から動いておらず、DB の軌跡が短い。これに対して WR は、フェイクにより DB を交わすために素早く移動したため、移動距離が長くなり、2 秒時点での軌跡も長く描写されることがわかった。一方、失敗の軌跡の特徴に着目すると、DB が WR の動きを予測し、並走していることが初期段階の軌跡から読み取れる。このことから、プレー

表5 時系列データセットを用いた実験結果

秒数		1	2	3	4	5	6	7	8
正例	データ件数	20							
	判定結果								
	正例件数	11.6	11.6	11.3	11.7	11.7	12.3	12.2	12.2
	負例件数	8.4	8.4	8.7	8.3	8.3	7.7	7.8	7.8
	適合率	0.581	0.566	0.519	0.521	0.509	0.515	0.508	0.510
	再現率	0.580	0.581	0.566	0.585	0.584	0.617	0.610	0.609
負例	F 値	0.571	0.564	0.531	0.538	0.539	0.556	0.550	0.549
	データ件数	20							
	判定結果								
	正例件数	8.6	9.2	10.4	10.5	10.5	10.9	11.1	11.0
	負例件数	11.4	10.9	9.6	9.5	9.5	9.1	8.9	9.0
	適合率	0.578	0.573	0.544	0.551	0.555	0.562	0.554	0.557
全体精度(平均)	再現率	0.572	0.543	0.482	0.473	0.477	0.457	0.447	0.450
	F 値	0.564	0.549	0.495	0.488	0.505	0.493	0.484	0.485
	適合率	0.579	0.569	0.531	0.536	0.532	0.539	0.531	0.534
	再現率	0.576	0.562	0.524	0.529	0.530	0.537	0.528	0.530
	F 値	0.568	0.557	0.513	0.513	0.522	0.525	0.517	0.517

を時系列ごとに分割することで、プレーの初期段階でも成否を導き出せることがわかった。

また、表5の3秒以降の全体のF値に着目すると、1、2秒時点と比較して精度が低下していることがわかる。その要因を分析するため、軌跡画像を目視で確認したところ、軌跡画像中のQBのパスタイミングを表す点が、3秒時点のデータには8割程度描画されている一方で、2秒時点では全体の約1割に留まっていることがわかった。このことから、パスタイミングの描写前（パスをする前）は、軌跡画像の特徴からパス成否が推定されており、パスタイミングの描写後（パスをした後）は、パスタイミングの点の位置関係などを学習したことの影響により、成否の推定結果が固定化したことが考えられる。そのため、パスタイミングが、成否の判定に影響を与えるものであると思われる。今後、この点を明らかにする必要があると言える。

以上の結果から、提案手法により移動履歴を考慮することで、プレー開始時、または開始直後におけるパス成否を一定の精度で提示できる可能性があることがわかった。

• WR と DB のプレー時の位置関係やその距離がパス成否の推定結果に影響する可能性があることがわかった

パス成否を深層学習により判断する時に、どのような特徴が考慮されているかを分析するため、時系列の軌跡画像を目視で確認した結果を図9に示す。図9のWR（赤色またはピンク色）とDB（青色または緑色）の位置関係から、パス成否を分ける特徴としてプレー時の位置関係やその距離が考慮されている可能性があると考えられる。例えば、成功率が常に0.9以上で成功と判定した軌跡画像の事例（図9上段）では、WRとDBの間に距離があり、WRは空いたスペースに走りこむことができる状態であった。しかし、失敗率が0.9以上で失敗と判定した事例（図9中段）では、DBがWRと同じルートを並走し、WRのパスコースの走行を妨げていることがわかった。また、成功率と失敗率が共に0.5前後の軌跡画像（図9下段）では、成功と失敗の軌跡画像に含まれる特徴が両方とも含まれていることがわかった。このことから、経時変化を考慮する場合、早

図8 時系列ごとの軌跡画像のパス成否の特徴

図9 時系列データセットの推定結果の一部例

い段階で、パスの成功率と失敗率が算出できる可能性を示唆できたと考えられる。

4.3 今後の展望

本研究では、アメリカンフットボールのパスプレーに関するマッチアップ分析の発展として、100種類以上あるプレーをWRの位置と走行方向に基づき大別して分類した3つのデータセットの精度比較を行った。その結果、プレーを細分化することで、軌跡画像の特徴をより正確に学習できる可能性があることが明らかとなった。さらに、プレーの時系列を考慮することで、WRとDBの位置関係や距離などの特徴に基づいてプレー

の成否を判定できる可能性があることを示すことができた。今後、プレーのデータ件数を増やし、推定結果の軌跡画像に基づく分析をより詳細に行う予定である。

5. おわりに

本研究では、既存研究 [13] で行ってきたパスプレーの発展として、プレー分類によるパス成否の判定の変化の検証と、移動履歴を考慮した場合のパス成功率と失敗率の精度の検証を行った。

その結果、前者では、プレーを細かく分類することで、少ないデータでも一定の精度でパス成否を推定可能であることがわかった。これは、パスごとに成功や失敗の特徴が近似し、容易に学習できることが原因と考えられる。また、後者では、プレーの進行中に変化するパス成功率と失敗率を算出できることがわかった。今後は軌跡を経過した秒数ごとに各選手の位置や間隔を解析し、失敗と成功の特徴の定量化を試みる予定である。これにより、本研究で長期目標としているプレーの初期段階で成否の判定を監督やコーチに提供するシステムを実現し、練習や実際の試合でのスクリーンを対象として、フォーメーションの配置から、どの WR にどのタイミングでパス投球すると成功率が向上するかをリアルタイムに監督やコーチに情報を提供することや、スポッターのトレーニングに適応することを目指す。

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, スポーツ振興法: http://www.shugiin.go.jp/internet/itdb_housei.nsf/html/houritsu/03819610616141.htm [accessed Dec. 14, 2018]
- [2] 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]
- [3] 文部科学省, スポーツ庁の創設とスポーツ政策の推進: http://www.mext.go.jp/b_menu/hakusho/html/hpab201601/detail/1376605.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] 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.

- [9] 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.
- [10] R. Li and R. Chellappa: "Recognizing Offensive Strategies from Football Videos," *Int. Conf. on Image Processing*, pp. 4585-4588, 2010.
- [11] 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.
- [12] I. Atmosukarto, B. Ghanem, S. Ahuja, K. Mutjuswamy, and N. Ahuja: "Automatic Recognition of Offensive Team Formation in America Football Plays," *Conf. on Computer Vision and Pattern Recognition Workshops*, pp. 991-998, 2013.
- [13] 田中ちひろ, 山本雄平, 姜文淵, 中村健二, 田中成典, 林勲: "アメリカンフットボールの可視化と深層学習によるパスプレーのマッチアップ分析に関する研究," 第 34 回ファジィシステムシンポジウム講演論文集, pp. 168-169, 2018.
- [14] 山本雄平, 田中成典, 中村健二, 姜文淵, 田中ちひろ: "GPS による戦略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," 第 33 回ファジィシステムシンポジウム講演論文集, pp. 297-298, 2017.
- [15] 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, 2018.
- [16] FITNESS APOLLO, Hudl 日本公式サイト: <http://hudl.jp/> [accessed Dec. 14, 2018]
- [17] 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.
- [18] Google, TensorFlow: <https://www.tensorflow.org/> [accessed Dec. 14, 2018]

(2019 年 1 月 18 日 受付)

(2019 年 6 月 12 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 ——

田中 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。

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。

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 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。

なかじま しんすけ
中島 伸介 [非会員]

1970 年生。1990 年神戸大学体育会アメリカンフットボール部（4 年間所属）。2004 年京都大学大学院情報学研究科社会情報学専攻博士後期課程修了。博士（情報学）。現在、京都産業大学情報理工学部教授。情報推薦および Web マイニングに関する研究に従事。

Research for Pass Matchup Analysis Considering Movement Records in American Football

by

Chihiro TANAKA, Yuhei YAMAMOTO, Wenyuan JIANG, Shigenori TANAKA, Kenji NAKAMURA, and Shinsuke NAKAJIMA

Abstract:

Japan Sports Agency aims at supporting distinguished performance of national members of Japan from a scientific aspect in the prioritized policy concerning improvement in international athletic ability. Focusing on the field sports, we have been developing a system for visualizing athletes' plays using the GNSS sensor. In particular, we have been performing a research on matchup analysis of pass plays with a focus on American football. The aim of the research was to decide whether a pass is completed or incompleting by deep learning, using trajectory images of matchup of QB, WR, and DB. However, since only the track information of the finished plays was used, it failed to obtain information perceived during the play, for example, prediction of the completed pass probability during the play, or information that enables directing timely choice or modification of action from the side line during the game based on the prediction values. In this research, we attempt to predict completion probability during plays by using track information that takes into account the time term. In experiments, we made analysis of quick passes, short passes, and long passes to demonstrate its usefulness.

Keywords: american football, pass play, matchup analysis, deep learning, time series analysis

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