

# 卒業論文

## 姿勢推定と物体認識を用いた ラグビーのキックパスの予測

指導教官 村上 陽平 教授

立命館大学 情報理工学部  
先端社会デザインコース 5 回生  
2600190117-5

北川 大夢

2023 年度（秋学期）卒業研究 3（CH）  
令和 6 年 1 月 31 日

## 姿勢推定と物体認識を用いたラグビーのキックパスの予測

北川 大夢

### 内容梗概

ラグビーにおいて、キックパスはトライにつながるとても重要なプレーである。そのため、キックの練習は重視されているが、キックは人によってフォームが全く違い、キッキングコーチが一人一人を的確に指導するのはとても難しい。また、キッキングコーチの人数自体が全国でとても少ない。さらに、公立の高校などでは、キックを蹴るスペースの確保ができずに、ネットに蹴って練習をするため、ラグビーボールを狙い通りに蹴れているかを確認できない。このような問題に対して、キックの姿勢データからニューラルネットワークを用いてキックの成否を予測するモデルが構築されている。しかしながら、既存のモデルではラグビーボールが固定されたコンバージョンキックを対象としており、移動するボールを蹴るキックパスでは、ボールの位置によって適切なフォームが異なるため、既存のモデルを適用できない。

そこで本研究では、姿勢データだけでなく、ボールの位置データも考慮したキックパスの着地予測手法を考案し、キックパスの成否を予測する。具体的には、キックパスの動画から姿勢推定の **OpenPose** を用いてキックパスの姿勢データを、物体認識の **YOLO** を用いてボールの位置データをそれぞれ抽出し、**LSTM** を用いてキックパスの予測モデルを生成する。本研究では、立命館大学体育会ラグビー部の協力の下、キックパスの動画を撮影し、それをもとに予測モデルを生成した。本手法の実現にあたり、取り組むべき課題は以下の2点である。

### 認識データのノイズ除去

キックパスの動画から選手の姿勢やボールの位置データを推定する際に、人やボールとは関係のないデータ（ノイズ）が混ざる場合があるため、それを除去しなければならない。

### キックの着地地点に影響を与える関節の同定

動画から推定される関節データにはキックパスの成否に直接関係のないものがあると考えられる。また、ラグビーのドメイン知識で必要と思われる関節が実はキックパスの成否に重要でない場合も考えられる。選手に正確な指導をするために、必要十分な関節を同定し、これまでのドメイン知識の妥当性をデータから検証する必要がある。

一つ目の課題では、**OpenPose** でデータを推定した際、ノイズの場合はデータ

内の **confidence** 値が低いと考えられる。さらに、ノイズは関節によっては取得できないものも多い。そこで、**confidence** 値の平均化を行い平均値の低いものの削除を行った。YOLO においてボール以外に認識した物体については、数値の左側のオブジェクト ID が同定できないかの確認を行った。

二つ目の課題では、異なる関節を対象とした二種類の姿勢データから、LSTM を用いてキックパスの予測モデルを生成し、予測モデルの精度を比較して、キックパスを成功させるための重要な要素である関節を特定する。具体的には、ラグビーのドメイン知識に基づいて取捨選択した関節を用いて学習した場合と、全関節データを用いて学習した場合の二つを用いてキックパスの予測モデルの構築をした。次にそのモデルを比較して、評価を行いドメイン知識に基づいて構築したモデルの妥当性を検証した。本研究の貢献は以下の通りである。

### **認識データのノイズ除去**

OpenPose を用いて推定された関節データからノイズの削除を行うために、OpenPose の **confidence** 値 (信頼度) の平均化を行い、平均値の低いものを削除した。これにより、全く関係ない **confidence** 値の低いノイズを除去することができた。

### **キックの着地地点に影響を与える関節の同定**

ドメイン知識に基づいて取捨選択をした関節を対象にした姿勢データと、全関節を対象にした姿勢データを用いてキックパス予測モデルを構築し、**Accuracy** の比較を行った。実験の結果から **Accuracy** は全関節 **70%**、ドメイン知識 **64.5%** であり、ドメイン知識である蹴る足の膝、蹴る足の足首、軸足の足首、軸足の膝、軸足の肩、右目、左目の有用性は統計的に確認できなかった。また、ボールの位置情報を加えなかった場合は **70%**、加えた場合は **60%** であり、ボールの位置情報の有用性も統計的に確認できなかった。しかしながら、どちらもエポック回数によっては、**80%**を検出したため、学習データを増やすことで、精度改善の可能性があると考えられる。

# **Predicting rugby kick passes using posture estimation and object recognition**

Hironu Kitagawa

## **Abstract**

In Rugby, the kicking pass is crucial for scoring tries, emphasizing the importance of kicking practice. However, teaching accurate kicking techniques poses a challenge for coaches due to the varying forms of kicks among individuals. The limited number of kicking coaches in Japan exacerbates this issue, particularly in public high schools where space constraints lead to kicking practice into nets. To address this, a neural network model has been developed to predict kick success based on kicking posture data. Existing models are effective for fixed rugby ball conversion kicks but fall short for kick passes with a moving ball, as the appropriate form depends on the ball's position.

In this study, we devised a kick-pass landing prediction method that considers not only posture data but also ball position data to predict the success or failure of a kick-pass. Specifically, we extracted the posture data of a kick pass from a video of a kick pass using OpenPose for posture estimation and YOLO for object recognition, and generated a prediction model of the kick pass using LSTM. In this study, the prediction model was generated based on the video of the kick pass taken in cooperation with the Ritsumeikan University Athletic Association Rugby Club. The following two issues needed to be addressed in order to realize this method.

## **Noise removal of recognition data**

When estimating player posture and ball position data from a kick-passing video, data (noise) that has nothing to do with the person or the ball may be mixed in, which must be removed.

## **Identification of joints that affect the landing point of the kick**

It is thought that some of the joint data inferred from the video may not be directly related to the success or failure of the kick pass. It is also possible that some joints that are considered necessary in the domain knowledge of Rugby may not actually be important for the success or failure of the kick pass. In order to provide accurate instruction to players, it is necessary to identify the

necessary and sufficient joints and to verify the validity of previous domain knowledge from the data.

For the first issue, when the keypoints are estimated with OpenPose, the confidence value in the data is considered to be low in the case of noise. In addition, many noises cannot be obtained for some joints. Therefore, we averaged the confidence values and removed those with low averages, and for objects recognized in YOLO other than balls, we checked whether the object IDs on the left side of the values could be identified.

In the second task, we generated a prediction model of a kick pass using LSTM from two types of posture data targeting different joints, and compared the accuracy of the prediction models to identify the joints that are critical for a successful kick pass. Specifically, we built a predictive model of kick-passing using two cases: one in which the model was trained using discarded joints based on rugby domain knowledge, and the other in which the model was trained using all joint data. The models were then compared and evaluated to verify the validity of the model built based on domain knowledge. The contributions of this study are as follows

### **Noise removal of recognition data**

To remove noise from the joint data estimated using OpenPose, we averaged the OpenPose confidence values and removed those with low average values. This allowed us to remove noise with low confidence values that had nothing to do with the data.

### **Identification of joints that affect the landing point of the kick**

We constructed a kick path prediction model using posture data for selected joints based on domain knowledge and posture data for all joints, and compared the accuracies. The experimental results could not validate the usefulness of the ball position and rugby domain knowledge: knee of the kicking foot, ankle of the kicking foot, ankle of the shaft foot, knee of the shaft foot, shoulder of the shaft foot, right eye, and left eye. However, the method that utilizes both the ball position and domain knowledge achieved an accuracy of 80% depending on the number of epochs, higher than the average accuracy in using all the joint points without the ball position.

## 目次

<b>第 1 章 はじめに</b>	<b>1</b>
<b>第 2 章 姿勢推定を用いたスポーツの支援</b>	<b>3</b>
2.1 姿勢推定手法	3
2.1.1 OpenPose	3
2.2 物体認識	5
2.2.1 YOLO	6
2.3 関連研究	6
2.4 キックパスとは	7
2.4.1 キックパスの仕組み	7
<b>第 3 章 キックパスの予測モデル</b>	<b>9</b>
3.1 データの収集	9
3.2 データクリーニング	10
3.2.1 姿勢推定データのノイズ除去	10
3.2.2 物体認識データのノイズ除去	11
3.3 LSTM によるモデル構築	11
<b>第 4 章 ドメイン知識に基づくモデル構築</b>	<b>13</b>
4.1 ドメイン知識	13
4.1.1 指導内容	13
4.1.2 アンケート結果	15
<b>第 5 章 評価</b>	<b>17</b>
5.1 全関節を用いた予測精度	17
5.2 物体認識を用いた予測精度	17
5.3 ドメイン知識を用いた予測精度	17
<b>第 6 章 考察</b>	<b>20</b>
<b>第 7 章 おわりに</b>	<b>22</b>
謝辞	23
参考文献	24

## 第1章 はじめに

近年、ラグビーワールドカップが開催されたことにより、国内でのラグビーの注目度が高まり、ラグビーの強化が行われている。ラグビーをする上でも最新の情報システムが導入されている。例えば、大学やプロ選手に **GPS** を付けることにより、選手1人1人の走行距離、スプリント回数などを計測し、選手の疲労を管理しパフォーマンス向上を試みている。その他に、ドローンなどのカメラを駆使し、グラウンド1人1人の選手の動き、チーム全体の動きを分析することによりチームプレー向上に繋がっている。一方で、ラグビーにおいて得点に繋がる一番重要なプレーのキックは、ラグビーのプレーの中でとても繊細であり、とても難しい。ラグビーのキックは大きく分け 4 種類に分かれる。その中でもキックパス(第2章2.4で記述)は試合の流れを大きく左右する重要なプレーとなっている。このプレーが成功することにより得点に近づくことができる。ここ数年でキックはとても注目され、ラグビー界ではキックを専門のプロコーチとして活動をする人も増えてきた。しかしながら、キックのフォームは人によって大きく違い、キック専門コーチが1人1人にあった指導をするのはとても難しい。専門のプロコーチ達は、自分の経験や考え方をもとに指導をするためその指導が正しいかは明らかではない。また、公立の高校などではキックを十分に蹴るスペースが狭く、キック練習場所の確保が難しい。そのため、練習量不足が問題視されている。このような問題に対して、キックの姿勢データからニューラルネットワークを用いてキックの成否を予測するモデルの構築がされている[5]。しかし、この既存のモデルではラグビーボールの固定されているコンバージョンキックを対象としており、本研究では、移動するボールを蹴るキックパスを対象とするために、ボールの位置によってフォームが変わるキックパスには適用することができない。

関連研究では、**OpenPose** を用いたバトントワリング選手のための動作改善システムの開発をするというものがあつた。**OpenPose** を用いて姿勢に着目し、改善を試みるという点では共通である。しかし、ラグビーは他の選手とフォームが異なるため、他選手のキックの姿勢データの比較にはならないと考える。

そこで、本研究ではキックパスの動画から **OpenPose** を用いてキックの姿勢データの収集、物体認識の **YOLO** を用いてボールの位置情報をそれぞれ抽出した。そして **LSTM** を使い、全関節、ドメイン知識に基づいた関節、ボールの位置情

報の有無のキックの予測モデルを生成する。本研究では、体育会ラグビー部の Y 君のキックパス動画を使用し、キック予測モデルの生成をした。被験者 Y 君のキックパス予測を可能とするものである。つまり、このキックパス予測モデルは被験者 Y 君のキックに対して可能な予測モデルである。本研究では、キックを蹴るスペースのない場所でのキックパスの動画からそのキックが成功か不成功かの成否を予測することにより、キックの実践的な練習量の増加を目的としている。

本手法の実現にあたり、取り組むべき点は以下の 2 点である。

### 認識データのノイズ除去

キックの動画から OpenPose を用いてデータを取得する際に、人間とは関係のないノイズが出現してしまう。ノイズが出現することにより、正確なデータ収集をすることができなくなるため、ノイズを除去しなくてはならない。

### キックの着地地点に影響を与える関節の同定

キックパス予測モデルを構築し、このモデルを使いながら指導する際に、キックを蹴る際に意識する関節が多すぎると難しい。また、動画から推定される関節データにはキックパスの成否に直接関係のないものがあると考えられ、ラグビーのドメイン知識で必要と思われている関節が実はキックパスの成否に重要でない場合も考えられる。選手に正確な指導をするために、必要十分な関節を同定し、これまでのドメイン知識の妥当性をデータから検証する。

以下、本論文では、第 2 章では今回使用した手法の一つである OpenPose に関する説明と OpenPose を用いた関連研究、もう一つの手法である YOLO の説明。そして、ラグビーのキックパスの説明をしている。第 3 章ではキックパスの予測モデルの構築と学習データについて説明をしている。第 4 章ではドメイン知識に基づくモデル構築に関して、ラグビーのキックパスのドメイン知識を踏まえながら説明している。第 5 章では、第 3 章と第 4 章のモデルを比較し考察の記述。第 6 章では、本研究のまとめを記述している。

## 第2章 姿勢推定を用いたスポーツの支援

本章では、姿勢推定がスポーツにどのように関係があるのかを関連研究の紹介も交えながら説明をする。また、本研究で用いた主な手法である OpenPose と YOLO についても説明をする。

### 2.1 姿勢推定手法

本節では、姿勢推定手法について説明をする。姿勢推定とは、画像や動画から人体や物体の関節点を推定し、関節点を結んだ姿勢情報を抽出する技術である。これは、関節や部位の位置や向きなどを数値化として捉え、対象の姿勢を理解することを可能にする。スポーツ分野におけるフォーム改善、セキュリティにおいて行動解析などの有名な活用例があげられる。姿勢推定を行う際は関節点を抽出する必要があるが、そこで使用されるものが主に OpenPose やモーションキャプチャーである。しかし、モーションキャプチャーで取得されたデータの解析や分析には専門的なスキルが必要であり、専門家を要する。また、とても高価であり、導入及びメンテナンスにとっても費用がかかってしまい、手をだしにくい。そこで、本研究ではスマホのカメラ 1 台で姿勢推定をできる OpenPose を用いた。次に OpenPose について詳しく説明をする。

#### 2.1.1 OpenPose

OpenPose とは、カーネギーメロン大学 (CMU) の Zhe Cao らによって CVPR2017 で発表された「Realtime Multi-person 2D pose estimation using Part Affinity Fields」が実装されたライブラリである[2]。OpenPose は、動画像を入力するだけで、画像内の複数人数のポーズをほぼリアルタイムで推定することができる。具体的には、25 個もの人の建設位置 (画像平面上での 2 次元座標) を求められる。(図 1) では、(表 1) 25 個の抽出される関節についての詳しい表である。既存手法では、画像から人が写っている領域の Bounding Box を検出したのちに、Bounding Box 内の人の Pose を推定するというアプローチが主流であった。一方、OpenPose は、1 枚の画像から複数人の Pose を同時に推定するために、画像からまずは各関節位置を Deep Learning を用いて推定する。各関節毎に 1 枚の confidence map, つまり右手首の confidence map という具合に計個の confidence map を求める。そして、それらの関節をつなぎ合わせることで人

の姿勢情報を得るわけである。この時、複数の人物が写っている場合、左肩と左ひじの繋ぎ方の組み合わせが複数存在することになってしまう。この組み合わせの中から正しいもの推定するために用いられているが PAFs (Part Affinity Fields) と呼ばれる手法である。これは、関節間が繋がり得る可能性を方向ベクトルマップとして予測するネットワークである。OpenPose では、映っている人数に関わらず 1 回の推論で Pose 推定が可能のため、リアルタイムに近い処理速度を実現しているというのが大きな特徴である。

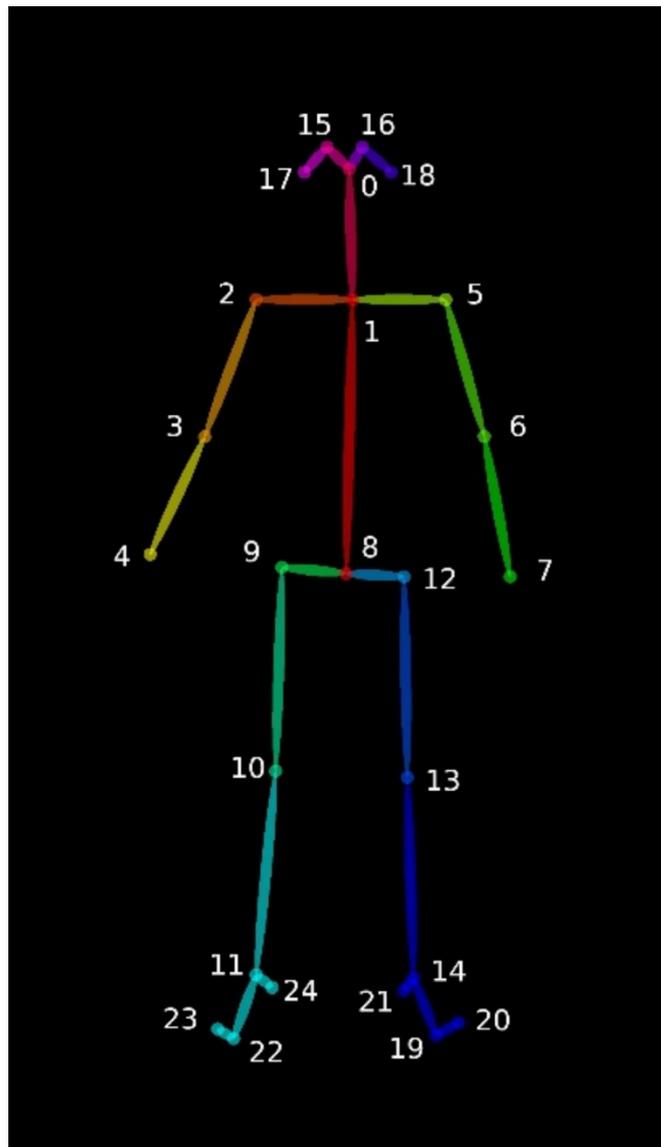


図 1 抽出した 25 個の関節

<sup>1</sup> <https://note.com/appai/n/nfe5d6bbd7bb2>

表 1 OpenPose の関節の部位番号の説明

ID	説明
1	首
2	右肩
3	右肘
4	右手首
5	左肩
6	左肘
7	左手首
8	腰中央
9	右腰
10	右膝
11	右足首
12	左腰
13	左膝
14	左足首
15	右目
16	左目
17	右耳
18	左耳
19	左つま先(根本)
20	左つま先(指先)
21	左かかと
22	右つま先(根本)
23	右つま先(指先)
24	右かかと
25	背景

## 2.2 物体認識

物体認識とは、画像や映像の中から、特定の物体の位置、種類、個数などの情報を認識する技術である。映像の中に何が、何個映っているかを瞬時に判断する脳の機能を AI で実現している。物体認識は主に、対象物体がどこにありそうかを絞り込む（バウンディングボックスの発見）そして、対象物が何であるかを分類（カテゴリーの判断）の 2 ステップで行われる。物体認識では、ディープラー

ニングの中で最も有名な CNN（畳み込みニューラルネットワーク）を基にした手法を利用することがほとんどである。特に、R-CNN、YOLO を用いることが多い。しかし、R-CNN は処理時間が非常に遅い、メモリを大量に消費することが挙げられる。そこで本研究では、リアルタイムで検出が可能な YOLO を用いた。次に、YOLO について説明をしていく。

### 2.2.1 YOLO

YOLO とは、リアルタイム物体検出において革新的なアルゴリズムの 1 つである[3]。この技術は、画像に映っている物体を迅速かつ精密に検出する能力を有している。YOLO は、「You Only Look Once」の略で、「1 度見るだけ」という意味を持つ。YOLO はその名が示す通り、1 度の視認だけで物体を検出するのが特徴である。畳み込みニューラルネットワーク（CNN）を活用し、1 回の画像走査で画像の中にある複数の物体を同時に検出し、識別する。YOLO には、自動運転、製造業の異常検知、セキュリティ対策などの分野で活用されている。YOLO には、以下の 4 つのメリットがある。1、全体像に基づく予測 2、ほぼリアルタイムでの検出が可能 3、推測の精度が高い 4、導入ハードルが高くないなどの特徴がある。

## 2.3 関連研究

OpenPose を用いた関連研究について紹介をします。藤原らの研究では、本研究でも利用した OpenPose を利用して、スポーツにおける共通の要素であるバトントワリング界の進展に貢献する取り組みを行っている[1]。具体的には、バトントワリング選手へのインタビューを通じて、成功と不成功の違いを提示する動作改善システムのコンセプトを構築した。最初に、加速度センサとオーバーレイ動画を組み合わせるシステムを開発し、バトントワリング選手に使用してもらった。しかし、このシステムは有用性が認められたが、加速度センサの使用による不便さが指摘をされた。そのため、選手の負担を減らすために映像のみを取得して動作確認する方向性に転換し、OpenPose を用いて成功と失敗を分ける動作のポイントを自動解析する研究に取り組んだ。この関連研究の目的は、バトントワリング選手がスランプを克服、あるいはスランプに陥らないように、動作を分析し、成功時と失敗時の違いを検出する手法を改善した。OpenPose を動画に適用し、成功時の各関節の座標を加算平均し、平均的な変化を把握した。その

後、各データと平均データの差分の絶対値の和を計算し、この差分の時間経過に伴う累積和を成功時と失敗時のデータで比較をした。結果として、部位ごとに累積和の成功時と失敗時の平均の波形に差が生じ、右手首のX軸（左右方向）が特に重要であることが明らかになった。また、失敗が急激に大きくなるのではなく、徐々にずれが生じてから失敗に至ることが確認された。そして、動画から失敗した際の、改善をすることができ、成功に向けての修正をすることが可能となり、このシステムの有用性が検証された。

## 2.4 キックパスとは

ラグビーにおけるキックとは、大きく分けて 4 種類あり、ボールを置いてけるキック（コンバージョンキック）、ワンバウンドさせるキック（ドロップキック）、転がす球を蹴るキック（グラバーキック）、浮かせる球を蹴るキック（パウントキック）である。その中の、浮かせる球を蹴るキックパスというキックは、ラグビーにおける戦術の 1 つである。この浮かせる球を蹴るキックは、キックパスにおいて主に使われることが多い。キックパスにも大きく分けて 2 種類があり、陣地獲得のためと得点獲得に分かれる。ラグビーのパスは自分より前に投げられないのに対し、キックでのパスは前でも反則にはならない。そのため、ラグビーにおいて大きな戦術の 1 つとなり、得点獲得のキックパスは最もトライ（ゴール）に繋がるプレーである。キックパスの成否によってゲーム展開が大きく変わるため、非常に重要なプレーとなる。

### 2.4.1 キックパスの仕組み

キックパスとは、ラグビーのゴールキック（コンバージョンキック）とは違い試合の流れで蹴らなくてはならない。キッカーに対して相手チーム 15 人は DF ライン上から誰でもプレッシャーをかけることができる。キックパスの一般的なシチュエーションは、SO、もしくは CTB の位置から一番大外の WTB に蹴るキックが主流である。WTB の前に DF がいない時に、ゲインを取るために、蹴ることが多いため、成功したらトライに繋がり、不成功の場合はボールが別の場所に行き、ピンチになる場合がとても多い。ミスをしたら相手ボールになるため高い技術を要する。そのため、とても重要なプレーあることがわかる。そして、蹴る瞬間は判断してから蹴るまでが一瞬であるため、正確にモーションにまで

入り自分のルーティン姿勢を作り，蹴らなくてはならない．そのため，日々の反復練習，試合シチュエーションでの判断がとても重要であり，必要である．

## 第3章 キックパスの予測モデル

本章では、ラグビーのキックパス予測モデルの構築について説明する。近年ラグビーワールドカップが開催され、日本代表の活躍により、国内でのラグビーの注目度が高まり、認知度が高まっている。しかし、ラグビーはサッカーや野球に比べて競技人口が少なく、マイナースポーツである。そのため、力を入れている私立高校などに比べ、公立の高校などでは、練習できるスペースが限られており、キックをできるスペースがとても少ない。そこで私は、キックを蹴るスペースがない場所でもキックの練習ができ、練習量増加につながるようこのキックパス予測モデルを構築したいと考えた。以下では、ラグビーのキックパスの説明から、どのように構築し、どのような精度になったかを述べる。

### 3.1 データの収集

キックパス予測モデルを構築するにあたり、まずキックパスの学習データとなる姿勢データを招集する必要がある。そこで本研究では立命館大学体育会ラグビー部の選手Y君に50回のキックパスを行ってもらい、50件のキックパス動画を取得した。(図3参照)キックを蹴る位置はラグビーグラウンドの22mラインと15mから横5m、縦5mの位置。正確な測定をするために、カメラの位置を22mラインと15mラインの2つのラインの交わる場所とする。ゴール地点は、その場所から、横50m、縦10mの位置に10m、10mの100平方メートルとする。オレンジがキック位置。青がゴール地点である。その枠内にボールが落ちたら(表2)のように成功○、外れたら不成功×と示した。

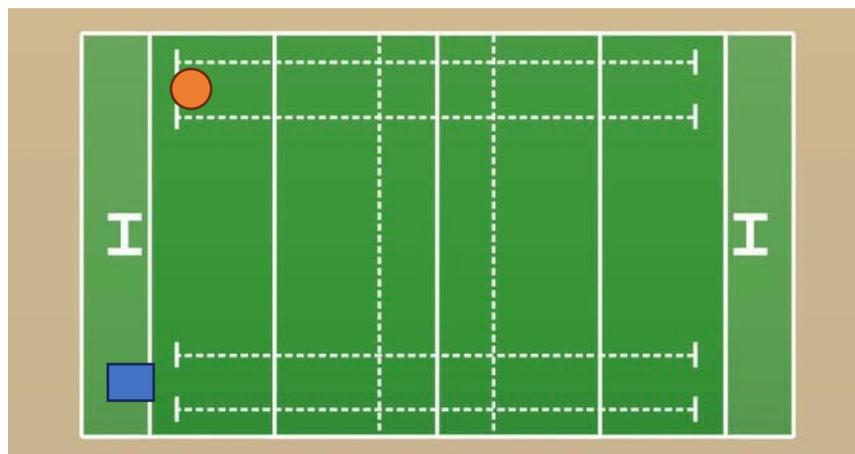


図3 実験の説明図

表 2 50 件のキックパス成否表

1	2	3	4	5	6	7	8	9	10
×	×	×	○	×	○	○	×	×	×
11	12	13	14	15	16	17	18	19	20
×	○	○	×	○	×	○	×	×	×
21	22	23	24	25	26	27	28	29	30
○	×	○	○	×	×	×	○	×	○
31	32	33	34	35	36	37	38	39	40
○	×	×	×	×	○	○	×	○	×
41	42	43	44	45	46	47	48	49	50
○	×	×	×	○	×	○	○	×	×

### 3.2 データクリーニング

上記で記述した動画データを、キックパスの予測モデルで使用できる姿勢データに変換をする必要がある。まずは、50 件のデータから OpenPose を用いて、25 点の関節を抽出し、50 件の Json データを作った。YOLO も同様に、物体の位置情報を抽出して、フレームごとに txt ファイルとして抽出をした。しかし、この抽出したデータの中には、ノイズと呼ばれるデータには関係のないものが含まれている。データクリーニングをすることにより、ノイズを適切に処理することで、データセットの品質向上ができる。品質向上は、研究結果の信頼性を高め、誤った結論を導く可能性を軽減させるため必要不可欠なものとなっている。

#### 3.2.1 姿勢推定データのノイズ除去

姿勢推定データ (OpenPose) のノイズには、必要な人間とじは関係のないデータが含まれてしまう。(図 4) は実際に動画を OpenPose にかけて時の 1 フレームである。この写真から見てわかるように、関係のないところにしせでーたが表れてしまうため、このノイズを除去しなくては、適切な姿勢データを風出することができない。本研究で行う OpenPose におけるノイズ除去は、抽出された複数の people には、それぞれ信頼値 (confidence score) を平均化し、最も平均値の高い people のみを残すという手法である。信頼値 (confidence score) とは、機械学習やコンピュータビジョンで使用される指標であり、モデルが行った予測や検出の正確性や信頼値を示す値である。信頼値 (confidence score) が高い場合、結果が正確であると考えられる。



図 4 OpenPose の 1 フレームの写真

一方、値が低い場合は、結果の信頼度が低い可能性がとて高くなる。これは関節ごとに値がついており、people ごとに平均化を行い低いものを削除することにより、正確に近い値をとることができる。

### 3.2.2 物体認識データのノイズ除去

物体認識 (YOLO) には、座標情報の正確性がとても重要である。しかし物体認識には、デメリットがあり、YOLO はグリッドの中心に物体があると仮定するため、物体の位置の精度が低くなることがある。また、1つのグリッドセルに1つの物体しか割り当てないため、密集した物体や重なった物体には、片方の物体が検出しなくなるという点である。抽出されたデータに座標データが (0,0) の場合は、ノイズや不正確な検出の可能性が非常に高い。そのため、マスクに True の代わりに False にすることにより、誤検出の影響を軽減することができる。

### 3.3 LSTM によるモデル構築

本研究では、キックパスの予測モデルを構築するために、深層学習 (ディープラーニング) 分野において用いられる人口回帰型ニューラルネットワーク、LSTM を用いた[4]。この LSTM とは、「Long Short-Term memory」を略した言葉である。LSTN とは、ディープラーニングがはやる前から存在していた手法であり、1997年に原著論文が発表された。LSTM とは、RNN (リカレントニュー

ラルネットワーク) という, 時系列を改良したものである. この **RNN** や **LSTM** は多くの時系列データを入力し, 何度も学習させることにより, 時系列データである出力を予測できるようになるという技術である. **RNN** には時間的に連続したデータを処理する能力があるが, 長期依存関係の学習が困難である. もともと **RNN** が抱えていた勾配消失問題を解消している. この問題を改良したのが **LSTM** であり, 最大の特徴である. 本研究では, キックパス予測モデルで用いた **LSTM** において, キックの関節データとキックの物体認識データを入力データとして, ゴールの成功不成功を教師信号として学習を行った.

## 第4章 ドメイン知識に基づくモデル構築

一章でも述べたように、近年日本でワールドカップが開催されたことにより、ラグビーの強化が加速している。近年では、プレー向上のためにラグビーにおいて、ほとんどのチームが IT 技術を活用している。ラグビーの練習や試合では、GPS を取り付け、スプリント回数や走行距離の計測、そして、カメラやドローン を計三台のカメラを活用し分析を行っている。また、Sportcode という編集ツールを使い、「タックル」、「キック」、「反則」などそれぞれのプレーに名前を付けて分析をすることにより、パフォーマンスの向上を図っている。しかし、キックパスにおいてチームで分析をしているチームは希少に近い。なぜなら、選手によってキックのフォームが異なり的確な指導をできないからである、そのため、キックパスはプロの選手がいままでの経験や知識を活かして指導するしかない。そこで、現状の指導内容や選手達の知識を参考にラグビーのキックパスにおけるドメイン知識に基づいたモデルを作成した。

### 4.1 ドメイン知識

ドメイン知識とは、特定の分野や領域に関する知識であり、その分野における専門的な用語や概念、ルールなどを含む。ドメイン知識を持つことは、その分野において専門家としての能力を発揮するために重要である。本節では、ラグビーのキックパスについてのドメイン知識について、現状の指導内容や選手の意見を踏まえながら紹介する

#### 4.1.1 指導内容

本節では、本研究で用いたラグビーのキックパスにおけるドメイン知識を決める上で参考にした指導内容である。この指導内容は元日本代表の君島良夫からお聞きしたものである。君島は現役時代試合で最もキックを蹴ることが多い SO というポジションでプレーしており、NTT コミュニケーションズ（現 NTT コミュニケーションズシャイニングアークス東京ベイ浦安）に所属をしていた選手である。君島は様々なチームを経験した後、現在は日本初のキック専用プロコーチ（キッキングコーチ）として全国を回り様々なチームを指導し活躍をしている。日本ラグビー界で名を轟かせている人物である。（表 3）の指導内容について説明をする。1、「足がボールに当たるまでの一貫性」が、ボールを持ってか

表3 君島のキックパス指導

1	足がボールに当たるまでの一貫性(ボールの落とし方)
2	軸足に注目(体の方向)
3	蹴った後の動作

らスイングするまでの動作が毎回同じであるということ。ボールを受け取ってから、キックするための歩幅、ボールの落とす位置はそれぞれリズムがある。時によって異なってしまうとフォームが変わってしまう。そして、足のスイングはボールの飛ばす方向、ボールの飛距離に非常に関係しているため、ここまでを一連の動作として身につけることが重要である。足のスイングをするためには、蹴る方の膝と足首が重要であると考えられる。2、「軸足に注目」は、キックを蹴る際の軸足（ボールの当たる足とは逆足）の事である。キックを蹴る際の、軸足の踏み込み、つま先の向きはキックをける上で必ず意識をしないといけないことである。軸足の歩幅は人それぞれではあるが、普段と違う歩幅にするだけで必ずキックは成功しない。つま先の向きも同様に、着地点を向いていないだけで成功することはない。3、「視線」は、ボールを持ってから蹴った後までの視線である。ボールを持ってから、ボールの落下させる位置を見てから、最後ボールが着地するまで目を離してはいけない。これは、ラグビーのプレーの中で、まずボールを蹴ろうとしている位置に相手がいなか確認してからキックという選択肢をとり、ボールをもらう。そしてもう一度確認することにより、相手がいなかを確認する。もう一度確認をする理由は、そこで相手がいる場合には別のプレーに切り替えなくてはならないからである。蹴っている途中もボールを見なくてはならないのは、しっかりボールを軸にあてなくてはならない事と、ボールを見ないことにより、胸が開き良い姿勢を取れないからである。最後まで見なくてはならないのは、自分の蹴ったボールの軌道を確認すること、蹴ったボールの結果によって次のプレーに切り替えなくてはならないからである。実際にボールを蹴っているときの写真が(図5)。最後まで見ているのが(図6)である。しっかりボールを見ているのがわかる。最後に「蹴った後に注目」は、走り出すイメージ、と指導をうける。走り出すイメージは、キックが想像した場所にまっすぐ飛ばすため、ボールに力がしっかり伝わるようにするには必要不可欠なことである。ボールを走り出すイメージで蹴ることにより、しっかり力を加えられ、的確なキックを蹴れる可能性が大幅に上がるからである。(図6)のように蹴った後



図6 蹴っているとき



図7 蹴った後

もしっかり走り出していることがわかる。

#### 4.1.2 アンケート結果

キックパスにおけるドメイン知識について立命館大学体育会ラグビー部に所属する 10 人のキッカーに「キックパスをするときに意識している関節を 3 つ

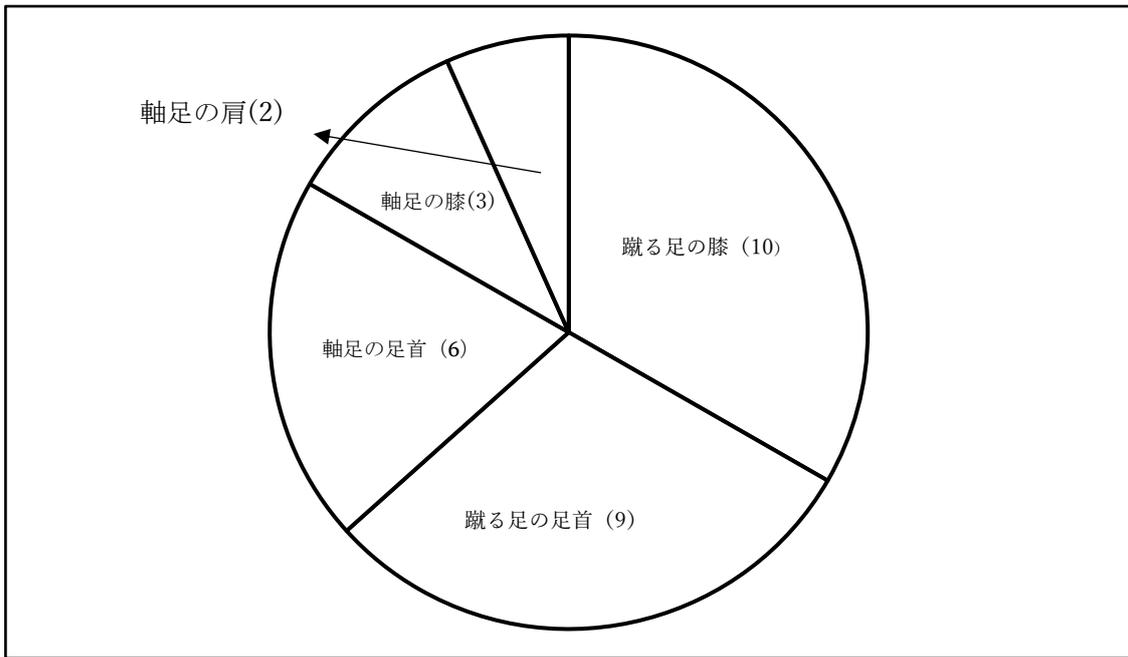


図 8 キックパス 10 人に対するアンケート調査結果

挙げて」というアンケートを取った。アンケートの結果を集計したものが(図 8)である。このアンケートに対象する 10 人が蹴る膝が重要であると答えた。また、10 人中 9 人が蹴る足首と答えたため、君島による指導内容と共通する関節であるため、キックパスにおけるドメイン知識の関節だといえる。また、軸足の足首が 10 人中 5 人。軸足の膝が 10 人中 4 人であり、軸足の足首、膝も先ほど同様にキックパスにおけるドメイン知識であるといえる。その他に、1 人ずつ軸足の肩、腰と答える選手がいた。

## 第5章 評価

本章では、全関節データを用いたキックパスの予測モデルの結果と位置情報を加えた予測モデルの予測精度の結果について説明をしていく。

### 5.1 全関節を用いた予測精度

本研究では、3.1でも述べたようにキックパスの動画50本撮影をした。トレーニングデータを50本学習させ、データセットを作成した。テストデータを10本抜き出し、その未知のモデルがまだ見たことのないものをどれくらいデータに適用できるかを評価した。予測モデルの精度をはかる際、ニューラルネットワークの重みの初期値をランダムに当てるため、精度が毎回同じになるとは限らない、そのため、複数回の精度の平均を出した。そして、モデルがトレーニングデータを見て、反復学習することにより、それに応じた正確値 (accuracy) を出した。機械学習においてトレーニングデータ全体がモデルに対して一度使用する時の単位をエポック (Epoch) とし、その学習回数に対する正確値 (accuracy) を評価した。図9のようにエポック1,5,10,15,20,25,30,35,40,45,50とし評価をした。エポック数が少なすぎるとモデルが不足している可能性があり、逆にエポック数が多すぎると過学習のリスクが生じる可能性があるため、適切な値に設定を刷る必要がある。精度の平均は70%であり、すべてのエポックにおいて同じであった。

### 5.2 物体認識を用いた予測精度

キックパスの指導を受ける際に、4.1.1で紹介をした足がボールに当たるまでの一貫性 (ボールの落とし方) という指導をキック専門プロコーチの君島から指導を受けたことから、ボールの位置は重要であるということがわかる。そこで今回も、比較をするために5.1のように評価をした。(図10)からわかるように全関節に比べ精度にばらつきがあり、平均は60%である。エポックが少なすぎると下がり、多すぎても下がってしまうということがわかる。

### 5.3 ドメイン知識を用いた予測精度

キックパスを蹴る際に意識する関節が多すぎると意識しづらくなることや、4章で紹介したアンケート結果から重要である関節から、ドメイン知識を蹴る足の膝、蹴る足の足首、軸足の足首、軸足の膝、軸足の肩、右目、左目と仮定して、

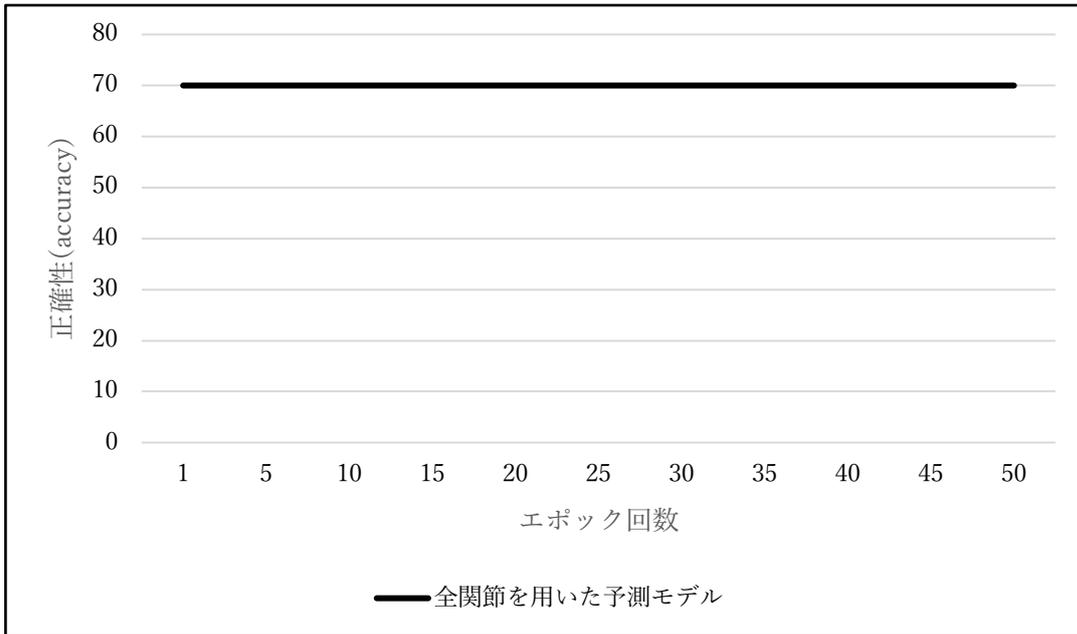


図 9 全関節を用いた予測モデル

それらの関節データを抽出した。本研究で用いたデータは右足利きの Y 君で撮影をしているため、2 章の表 1 より、5 左肩、10 右膝、11 右足首、13 左膝、14 左足首、15 右目、16 左目の計 7 箇所の関節を抽出し、予測モデルを構築し評価した。(図 11) からわかるように 5.2 と同様にばらつきがあり、平均は 64.5% である。

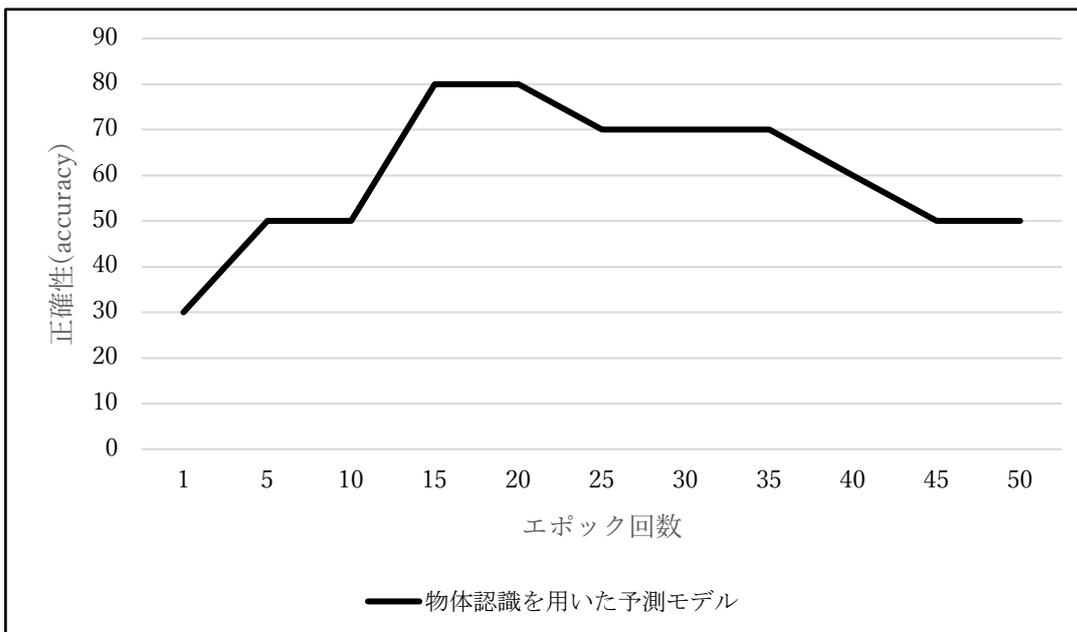


図 10 物体認識を用いた予測モデル

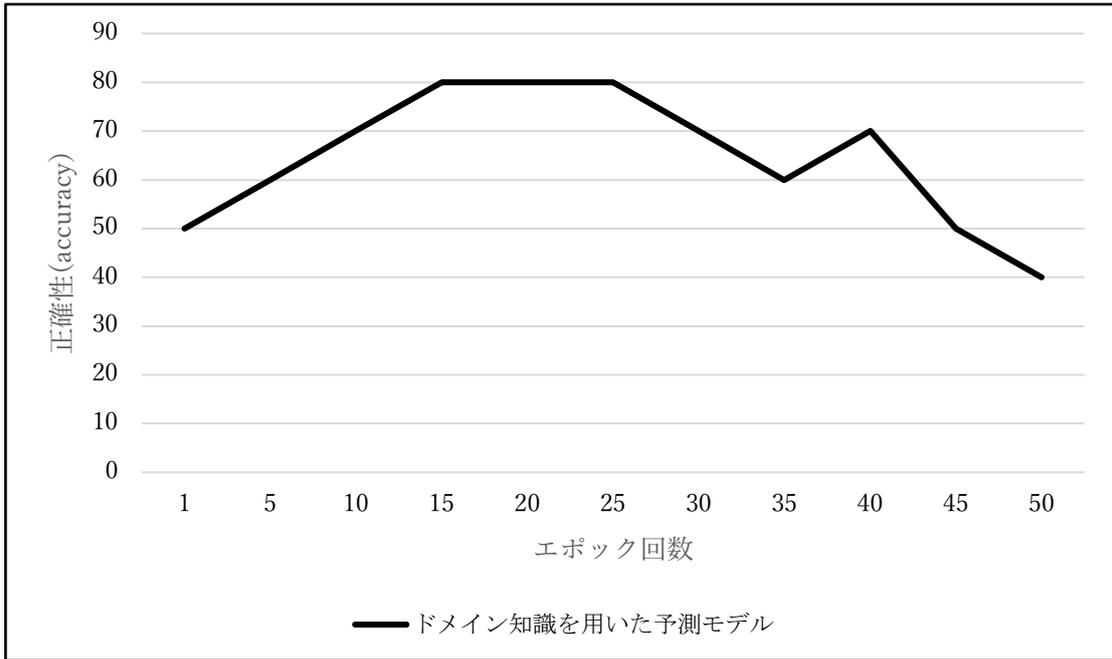


図 11 ドメイン知識を用いた予測モデル

## 第6章 考察

第5章でキックパスの動画から、姿勢情報、物体情報を用いて予測モデルの作成をした。全関節を用いた予測モデル、指導内容をもとに重要であるボールの物体情報を用いた予測モデル、選手からのアンケートや指導内容をもとにした関節を取り出したドメイン知識を用いた予測モデルを用いて比較をし、キックパスにおける位置情報とドメイン知識の関節の有用性について比較をした。

全関節を用いた姿勢モデルでは、すべて70%であり、平均も70%という値を検出した。すべてのエポック回数において70%であると考えられる原因としては、未知のモデルの動画が、失敗、成功において関節に明らかな差が生じているためである。キック失敗した際に、あと少しで成功というキックが未知のモデルの動画にはなかったために、このような結果になった。

物体認識を用いた予測モデルでは、全関節を用いた予測モデルに比べて平均は60%と低い結果であった。しかし、エポックの回数によっては80%と全関節を用いた予測モデルに比べ高い数値を検出しており、キックパスにおける物体の位置情報は有用性であることがわかる。この数値が60%と低い原因は、キックを蹴る際の、成功不成功動画ともに位置情報におけるずれが少ないからである。しかし、うまく動画を判定できている場合では、ボールの落とし方や人間との位置関係に大きく違いが生じていて人間の目から見てもわかりやすいからである。こちらも、全関節モデル同様に、あと少しで成功というキックが未知のモデル動画になかったのが原因であることが考えられる。本研究では、XY座標の2次元上での予測モデル構築であったため、成功キック、不成功キックに座標の差がないために平均数値が低いことが考えられる。また、これにボールの正しい位置情報Z軸の座標を組み込むことにより、この検証より高い数値で立証され、新たな問題や新たな発見が見いだされると考える。

ドメイン知識を用いた予測モデルに対しても同様に、64.5%と全関節を用いた予測モデルを下回る結果であった。しかし、エポック回数においては80%を検出しており、この結果からドメイン知識の関節として用いた、蹴る足の膝、蹴る足の足首、軸足の足首、軸足の膝、軸足の肩、右目、左目はキックパスにおいて有用であることが検証された。この結果においても、80%と高い判定を受けている。動画では、ドメイン知識である関節に失敗と成功で大きな誤差が生じているため、このような結果が出たと考えられる。判定が低い原因としては、エポック

回数が低い場合と多い場合にて、数値が低くなっていたため、学習の少なさ、過剰学習が原因であるとされる。

本研究では、全関節モデルに比べ、物体認識を用いたモデル、ドメイン知識に基づいたモデルは平均が低いものとなっている。しかし、エポック回数を適切なものにより、お互い **80%**と高い結果を検出していることから、それぞれ有用性を実証できるものとなったと考える。

## 第7章 おわりに

本研究では、キックパスの動画から、OpenPose を用いて関節データを取得し、YOLO を用いて物体の位置データの取得をし、キックパスの成否の予測をした。キックパスの動画 50 件のデータ収集を行った。しかし、データの中には、OpenPose, YOLO それぞれにノイズが含まれており、的確なデータ数値を出すことができなかった。そこで、OpenPose, YOLO とともにノイズを除去することにより、的確なデータの収集に成功した。また、本研究では、キックの着地地点に与える同定、物体認識の有用性を検証するために、ドメイン知識に基づいて選択したデータとボールの位置情報に基づいたデータ。そして、全関節を対象としたデータにより、予測モデルの構築を行いそれぞれの精度比較を行った。実験結果から、ドメイン知識に基づいた姿勢モデル、ボールの物体認識を用いたモデルとともに、全関節を対象としたモデルよりも高い数値の精度を検出し、キックパスにおけるドメイン知識である、蹴る足の膝、蹴る足の足首、軸足の足首、軸足の膝、軸足の肩、右目、左目が重要な関節であること、そしてボールの位置情報が重要であることが、キックパスにおいて重要であることが検証された。よって、現在のラグビー指導の知識は正しいものである。

本研究では、物体認識を用いる際に 2 次元上でしかデータ収集を行っていない。ラグビーは特殊なボールであり、少し位置が変わるだけで結果も変わると考える。そして、天候やプレッシャーのないことを前提にし、予測モデルの条件には入れていない。しかし、実際の試合では、天候や相手選手からのプレッシャーなども考慮しなくてはならない。このような条件を含めたキックパス予測モデルの構築ができれば、より実用性のあるモデルに近づくと考える。そして、3 次元の物体認識も含めたモデルを構築することにより、ラグビー界では認知されていない新たなキックに重要な関節の発見に繋がるかもしれない。

## 謝辞

本研究を行うにあたり，熱心なご指導，ご助言を賜りました村上陽平教授に深く御礼申し上げます。また，本研究のアンケートなど協力してくださった立命館大学体育会ラグビー部の皆様にも心より感謝申し上げます。

## 参考文献

- [1] 藤原 大智, 大須賀 美恵子: OpenPoseを用いたバトントワリング選手のための動作改善支援システムの開発, 人間工学, 57巻, Supplement 号, pp. 1D2-5(2021).
- [2] Z. Cao, G. Hidalgo, T. Simon, S. Wei, and Y. Sheikh: Openpose: Realtime Multi-Person 2D Estimation Using Part Affinity Fields, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 43, no. 1, pp. 172-186 (2021).
- [3] A. Bochkovskiy, C. Wang, and H.Y.M. Liao: YOLOv4: Optimal Speed and Accuracy of Object Detection, arXiv preprint arXiv:2004.10934(2020).
- [4] F. A. Gers, J. Schmidhuber, and F. Cummins: Learning to forget: continual prediction with lstm, Technical Report IDSIA 01-99,(1999).
- [5] M. Pituxcoosuvarn and Y. Murakami: Rugby Goal Kick Prediction Using OpenPose Coordinates and LSTM, in Proceedings of 26th International Computer Science and Engineering Conference (ICSEC), pp. 161-166, (2022)