

# 卒業論文

## 姿勢推定を用いたスクラムの優位性判定モデル

指導教官 村上 陽平 准教授

立命館大学 情報理工学部  
先端社会デザインコース 4回生  
2600190142-6

小松 大輝

2022年度（秋学期）卒業研究3（CH）  
令和5年1月31日

## 姿勢推定を用いたスクラムの優位性判定モデル

小松 大輝

### 内容梗概

近年、ラグビーワールドカップが国内で開催されたことにより、国内でのラグビーの強化が進んでいる。特に、スクラムは、そのプレー一つでボールの主導権が変わり試合の流れを左右するため、ラグビーにおいて非常に重要なプレーである。このようにスクラムの強化は必要であるが、ただ体格の大きい選手を集めたり、筋力トレーニングを増やしたりするだけでは十分ではない。スクラムは純粋な力比べのように見えて、体の向きや角度がほんの少し違うだけで前進したり、後退したりしてしまうような技術が必要などとも繊細なプレーである。さらに、スクラムは選手個人やチームの方針などによって押し方が変わるため、専門的な指導が難しいプレーでもある。近年ではスクラムコーチというスクラムを指導することに特化したコーチも存在する。しかしながら、日本の公立高校のほとんどは大学の強豪校やプロのチームのように専門的な知識を持っている指導者がいない場合、基礎的な姿勢の練習でも専門的な知識を持っていない指導者はその姿勢が正しい姿勢なのかを判断することは難しく、満足な指導ができていない。

そこで、本研究では基礎的なスクラムの画像から抽出された姿勢データを用いてスクラムの優位性の判定モデルを生成し、スクラムの前進確率を高める関節を特定する。具体的には、OpenPoseにより姿勢データを抽出し、MLP（多層パーセプトロン）によって優位性判定モデルを学習する。なお、本研究では立命館大学体育会ラグビー部の協力を得て、スクラムの画像を撮影した。

本手法の実現するために、取り組むべき課題は以下の2点である。

### 判定モデルの構築

前進確率を高める関節を特定するには、前進するか後退するかの確率を予測するスクラム優位性判定モデルが必要である。一旦、判定モデルが獲得されると、その判定モデルを用いて、多様なスクラムの前進確率を予測することができる。

### スクラムで有用な関節の探索

作成した優位性判定モデルを用いて、進行方向に進む確率を向上させる重要な関節の組み合わせを特定し、その関節をどちらに動かすことで前進確率を向上できるかを探索する必要がある。また、探索においては、関節が現実的でない位置を示す場合があるため、各関節間の距離や角度を考慮する必要がある。

一つ目の課題に対して、今回の研究では機械学習の一つである MLP（多層パーセプトロン）を用いる。まずは、OpenPose を用いてスクラムの画像から選手の関節データを取得する。次に、関節データを上下左右に水平移動することで、学習データを拡充した。拡充したデータを用いて、MLP の学習を行う。

二つ目の課題に対して、姿勢データの関節を絞り込みながら、優位性判定モデルを構築し、判定精度に寄与する関節を同定する。次に、その同定した関節に対して、上下左右に水平移動させて、スクラムの優位性を高める関節の位置を探索した。

提案手法の有用性を示すために、提案手法を組み込んだシステムを実装し、動作確認を行った。本研究の貢献は以下の通りである。

### **予測モデルの構築**

100 件のスクラム画像から 4000 件に画像を拡充した。100 件のスクラムの画像の accuracy は 50% を達成しており、拡充したデータを用いて学習した優位性判定モデルでは、データを拡充するほどにノイズも増えてしまったと考えられるため、accuracy は 40% を下回っている。

### **スクラムの優位性予測に有用な関節の検証**

関節数を絞り込んだところ、股関節、背中、膝、足首といった関節が、スクラムの前進、後退において特に重要な関節と同定し、その関節を用いた予測モデルの accuracy は 60% を達成した。さらに、専門家へのアンケートにより得られた正しいスクラムのフォームに従い、後退したスクラムの姿勢データを股関節と膝関節の水平方向の位置が等しくなるように補正して判定を行った結果、8 割のスクラムが前進と判断された。これにより、データから学習した判定モデルによって、既知のフォームの妥当性が検証された。

## **Scrum Superiority Determination Model Using Posture Estimation**

Daiki Komatsu

### **Abstract**

In recent years, the Rugby World Cup has been held in Japan. The scrum is a very important play in rugby because the control of the ball changes and affects the flow of the match depending on the scrum. Thus, strengthening the scrum is necessary, but simply recruiting bigger players and increasing strength training are not enough. The scrum may appear to be a pure contest of strength, but it is a very delicate game that requires skill, as the slightest difference in the direction or angle of the body can cause a player to move forward or backward.

Furthermore, the scrum is a difficult game to teach professionally, as the way of pushing changes according to the individual players and the team's policy. In recent years, there are scrum coaches who specialize in teaching the scrum. However, most public high schools in Japan do not have coaches with the same level of expertise as strong university schools or professional teams, and it is difficult for coaches without such expertise to judge whether the basic posture is the correct one.

Therefore, in this study, we generate a dominance decision model for scrum using posture data extracted from basic scrum images, and identify joints that increase the probability of Scrum advancement. Specifically, the posture data is extracted by OpenPose, and the dominance decision model is learned by the multilayer perceptron (MLP). In this study, images of scrums were taken with the cooperation of the Ritsumeikan University Athletic Association Rugby Club. The following two issues need to be addressed in order to realize this method.

### **Construction of a judgment model**

In order to identify joints that increase the probability of advancing, a scrum dominance decision model that predicts the probability of advancing or retreating is necessary. Once a decision model is obtained, it can be used to predict the forward probability of various scrums.

### **Search for Useful Joints in Scrum**

Using the dominance decision model, it is necessary to identify important joint

combinations that improve the probability of moving forward in the direction of progress, and to search for which of these joints can be moved to improve the probability of moving forward. In addition, the distance and angle between each joint should be considered in the search, since joints indicate unrealistic positions.

For the first task, in this study, we used MLP (multilayer perceptron), a machine learning technique. First, joint data of players were obtained from scrum images using OpenPose. Next, we expanded the training data by moving the joint data horizontally up, down, left, and right. The expanded data is used to train MLP.

For the second task, we constructed a dominance judgment model by narrowing down the joints in the posture data, and identified the joints that contribute to the judgment accuracy. Next, the identified joints were horizontally shifted up, down, left, and right to search for joint positions that increase the superiority of the scrum. To demonstrate the usefulness of the proposed method, we implemented a system incorporating the proposed method and verified its operation. The contributions of this study are as follows:

### **Construction of a prediction model**

We expanded the number of images from 100 scrum images to 4000 images. 100 scrum images achieved an accuracy of 50%, and in the dominance decision model trained on the expanded data, the accuracy was below 40% because noise is considered to have also increased as the data was expanded. The model for judging superiority trained on the expanded data is below 40%.

### **Verification of useful joints for predicting dominance of scrum**

After narrowing down the number of joints, the hip, back, knee, and ankle joints were identified as particularly important joints for scrambling forward and backward, and the accuracy of the prediction model using these joints was 60%. Furthermore, according to the correct scrum form obtained from the expert questionnaire, the posture data of the backward scrum was corrected so that the horizontal positions of the hip and knee joints were equal, and as a result, 80% of the scrums were judged to be forward scrums. As a result, 80% of the scrums were judged to be forward scrums. This verified the validity of the known form using the judgment model learned from the data.

# 姿勢推定を用いたスクラムの優位性判定モデル

## 目次

<b>第 1 章</b>	<b>はじめに</b>	<b>1</b>
<b>第 2 章</b>	<b>姿勢推定を用いたスポーツの支援</b>	<b>3</b>
2.1	関連研究	3
2.1.1	バスケットボール・フリースローの命中予測	3
2.1.2	OpenPose によるフィールド全域画像からのサッカー選手の識別	3
2.2	ラグビーのスクラムとは	4
2.2.1	ラグビーのスクラムのルール	4
2.3	OpenPose	6
<b>第 3 章</b>	<b>スクラムの優位性判定モデル</b>	<b>10</b>
3.1	モデル構築の概要	10
3.2	姿勢データの収集	11
3.2.1	画像から姿勢データの抽出	11
3.3	MLP によるモデル構築	12
<b>第 4 章</b>	<b>スクラムの姿勢改善</b>	<b>14</b>
4.1	ドメイン知識	14
4.1.1	指導内容	14
4.1.2	選手に対するアンケート	15
4.2	改善方法	16
<b>第 5 章</b>	<b>実験</b>	<b>17</b>
5.1	全関節を用いたモデルの予測精度	17
5.2	ドメイン知識を用いたモデルの予測精度	18
5.3	スクラムの改善案の妥当性	20
<b>第 6 章</b>	<b>考察</b>	<b>22</b>
<b>第 7 章</b>	<b>おわりに</b>	<b>24</b>
	謝辞	26
	参考文献	27

## 第1章 はじめに

近年、ラグビーワールドカップが国内で開催されたことにより、国内でのラグビーへの注目がより高まっている。そのラグビーの世界にも情報化が進んでいる。例えば、大学の強豪校やプロのチームでは **GPS** を用いて走行距離やスプリント回数を測定、ドローンを用いてグラウンドを多様な角度から撮影など以前は使われていなかった技術は現在では当たり前のように分析に使われている。一方で、スクラムというプレー（第2章 2.2 にて記述してある）は体の向きや角度がほんの少しでも違うだけで前進し、逆に後退してしまうような純粋な力比べのように見えて、技術が必要などとも繊細なプレーである。そのスクラム一つでボールの主導権が変わり、試合の流れを左右するととても重要なプレーである。昨年の第58回ラグビー大学選手権の準決勝の京都産業大学対帝京大学戦でもスクラムで優位に立てていた京都産業大学が、後半から帝京大学のスクラムに劣勢を喫して反則を繰り返し、最終的に逆点負けを喫した。このようにスクラムの強化は必要であるが、ただ体格の大きい選手を集めたり、筋力トレーニングを増やしたりするだけでは十分ではない。また、スクラムは選手個人やチームの方針などによって押し方が変わって来るので、専門的な指導をするのがとても難しいプレーでもある。なので、近年ではスクラムコーチというスクラムを指導することに特化したコーチも存在する。しかし、日本の公立高校のほとんどは大学の強豪校やプロのチームのように専門的な知識を持っている指導者がいない場合が多いので、基礎的な姿勢の練習でも専門的な知識を持っていない指導者はその姿勢が正しい姿勢なのかを判断することは難しく、満足な指導ができていないのが現状である。また本格的なスクラムの練習を行うには16人というとても多くの人数が必要になってくると、8人で練習するにしてもスクラムマシンは簡単に変えるような値段ではないので、スクラムマシンを持っていないかたり、持っても老朽化が進んでいて使えなかつたりするように簡単に練習できるようなプレーではないというのも公立高校がスクラムの練習を満足にできていない理由の一つでもある。

関連研究では **OpenPose** によるバスケットボールのフリースローのフォームに着目して、フリースローの命中予測を行っているものやサッカーのシュートのフォームに着目して、自動でプレーを評価するというものがあった。それらは **OpenPose** を用いて姿勢推定を行うという点においては、共通している部分では

あるが、やはりラグビーのスクラムの姿勢推定となるとまだまだ日本ではラグビーはサッカーやバスケットボールに比べてメジャーなスポーツではないので、研究はあまり行われていなかった。

そこで、本研究ではラグビーのスクラムの動画から **OpenPose** により姿勢データを抽出し、**MLP**(多層パーセプトロン)を用いてスクラムの優位性予測モデルを作成し、スクラムに重要な要素となる関節を特定する。このモデルはスクラムの練習において最も基本的な実践練習で **1v1** のスクラムの動画を予測するモデルである。本研究ではフロントローの選手がほとんどいない公立高校や合同チームが壁に向かってスクラムの姿勢を行う際にそのスクラムの姿勢の優位性を判定することで、スクラムの練習量を増加する事。また、スクラムを組む際に重要である関節を特定することを目的とする。

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。

### **予測モデルの構築**

スクラムの優位性予測モデルを構築するには、スクラムの動画からデータを抽出し、そのデータをもとにモデルを作成するので、動画からモデルの作成に使えるようにデータを抽出しなければならない。

### **スクラムの優位性予測に有用な関節の検証と有用な角度の探索**

また、スクラムの優位性の予測モデルを作成し、このモデルを使用しながら指導する際、意識すべき関節が多すぎると指導が難しくなる。また、スクラムのドメイン知識からスクラムを組む際にあまり重要ではない関節があると推測されるため、選手たちに正確な指導を行うためにも、必要十分な関節を特定する。さらに、スクラムの改善案を考案するために、スクラムが前進する確率を高める姿勢を探索する。

以下本論文では、第 2 章にラグビーのスクラムの説明と姿勢推定手法の 1 つである **OpenPose** に関する説明、**OpenPose** を用いた関連研究を説明している。第 3 章ではスクラムの優位性予測モデルの構築と構築に使用した **MLP** について説明している。第 4 章ではドメイン知識に基づいたモデルの構築についてドメイン知識の概要を踏まえながら説明している。第 5 章では、全姿勢データを用いたスクラムの優位性予測モデルの予測精度の結果とドメイン知識を用いたモデルの予測精度について説明している。第 6 章では第 5 章の結果を踏まえて精度を比較し考察を記述、第 7 章では本研究のまとめを述べた。



## 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おいてどのような影響を与えているのかを関連研究の紹介も交えながら説明していく。また、本研究において主に使用する OpenPose についても説明していく。

### 2.1 関連研究

本節では OpenPose を用いた関連研究を紹介する。

#### 2.1.1 バスケットボール・フリースローの命中予測

中井らは、本研究でも使用した OpenPose を活用し、スポーツという点で共通点のあるバスケットボール界の発展に貢献している[1]。具体的に概要を説明する。まず、バスケットボール界では試合のシュート本数やボール奪取などの回数データが試合ごとに大量に記録されているので統計モデルを用いた勝敗予測モデルが可能だった。また、大量の姿勢データが必要になるが、LSTM などを用いてバスケットボールの投入予測などが行われていた。その際のスポーツ動作の解析には、従来はビデオを静止画に分割してから姿勢位置を抽出するのが大多数であった。一方で姿勢データを直接抽出する方法として体の部位に直接センサーやモーションキャプチャーを装着して観測していたが、データ取得が盆雑なために回帰のような統計モデルが使えず、上級者と初心者の区別しかできなかった。この関連研究では、バスケットボールのシュートシーンに着目し、51 人のバスケットボールプレイヤーのシュートシーンから OpenPose を用いて特徴量を抽出し、特徴量と命中結果からロジステック回帰を行い、命中予測を行った。この研究はシュートが命中したかしていないかの 2 値の教師データのみで行っており、検証結果としては、51 人の内、41%が有効な判別モデルが構築されていることが示され、特徴量の解釈でもこのモデルの有効性を確認した。

#### 2.1.2 OpenPose によるフィールド全域画像からのサッカー選手の識別

山本らは、本研究でも使用した OpenPose を活用し、スポーツという点で共通点のあるサッカー界の発展に貢献している[2]。具体的に概要を説明する。まず、日本では 2020 年の東京オリンピックなどの大きなイベントに向けて、各スポーツ選手の競技水準を向上するための政策が進められてきた。このような背景の中で、ICT を活用したスポーツの研究が盛んに行われている。その中で、ス

スポーツの戦術分析を実現するために選手の移動軌跡の取得やプレー分析などの研究が存在する。これらの研究は、GNSS（衛星測位システム）と呼ばれる衛星を用いて選手の位置特定や追跡を行える技術や画像処理などの技術を用いて、選手の位置特定や追跡を行ってきた。しかし、GNSSを用いれば容易に選手の位置情報や追跡を行えるが、スポーツのルールによっては装着できない場合がある。一方、画像処理では選手に装着するセンサーは必要としないが、オクルージョンする選手の識別が困難である。そこで、この関連研究ではサッカーを対象として、1台のビデオカメラで撮影したフィールド全体の映像を用いて、画像拡大処理、コンストラクタの向上処理とシャープ化処理を適用し、OpenPose を利用することで選手を識別可能なシステムを構築している。このシステムを用いて、試合の映像から54秒ごとに1フレームを抽出し、計100フレームの画像に提案手法を適用することで、選手の識别人数と適合率、再現率などの平均を求めた。結果は識別率の平均が0.66であり、最も識別率が低いフレームは23人中8人しか認識しておらず、カメラから遠い距離の選手を識別する場合はより高解像なカメラの利用が必要であると考えられたが、最も識別率の高いフレームは23人中21人の識別が可能となっている。この精度はトラッキングに応用可能であることから、提案手法が有用であることがわかった。

## 2.2 ラグビーのスクラムとは

スクラムとはラグビーというスポーツにおけるプレーが切れた際、試合再開の時に行ういわゆるセットプレーの1つである。ノックオン、スローフォワードのようなラグビーの反則の中で比較的軽めの反則やボールがラックやモールの中から出なかった時に行うプレーである。また、ボールがタッチラインを超えてしまった場合はラインアウトというラグビーにおけるもう1つのセットプレーでプレーが再開となる。スクラムというプレーはラグビーのプレー人数である15人の内、フォワードと呼ばれる8人のプレーヤーが3列に組み合わさって押し合うプレーである。スクラムではフロントローと呼ばれるスクラムにおける前1列のプレーヤーが相手の前1列と組み合い、連結し押し合うプレーであり、前1列以外の選手は実際に相手のプレーヤーを押し出すことはなく、前1列のプレーヤーを押し出すことでスクラムに参加している。

### 2.2.1 ラグビーのスクラムのルール

では、ラグビーのスクラムのルールについて説明していく。



図 1 : 8v8 のスクラム

表 1 : スクラム内での反則

反則名 (FK はフリーキック, PK はペナルティキック)	反則の説明
ノットストレート (FK)	スクラムにボールをまっすぐに入れることができなかった場合の反則.
フットアップ (FK)	スクラムにボールが入る前にフッキングの動作をした場合の反則.
アーリーエンゲージ (FK)	レフェリーのコールに合わせてスクラムを組まなかった場合の反則.
ピックアップ (PK)	スクラムの中のボールを拾い上げた場合の反則.
クラッピング (PK)	故意にスクラムを崩した場合の反則.


このように、スクラムというプレーの中にもこれだけの反則がラグビーには存在する。また、スクラムというプレーは経験者から見てもどちらが反則を犯し

たのかがわからない場合があるように、わかりづらい反則がよく起こるプレーでもあるので、初心者ではまずどの反則かを見分けることは基本不可能である。

### 2.3 OpenPose

姿勢推定とは、動画・静止画から人物の関節点を推定し、関節点を結んだ人物の姿勢を検出する技術であり、画像認識の分野の1つである。近年、姿勢推定の技術は様々な場面で活用されており、スポーツのフォームの改善や自動運転の際、車載カメラからの人物の検出などが姿勢推定の技術の有名な活用の例である。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を体に取り付けて姿勢推定を行う場合はデータ取得が煩雑な場合がある。また、モーションキャプチャーを使用する場合、モーションキャプチャー自体が高価な物であるため、手を出しにくい。そこで、本研究では安価なカメラ1台で撮影した動画から姿勢推定を行うことができる OpenPose を用いた。次節にて、OpenPose について詳しく説明する。

OpenPose とは、カーネギーメロン大学 (CMU) の Center for Technology Transfer and Enterprise Creation で開発され、Zhe Cao らが「Realtime Multi-Person pose estimation」の論文で発表した、深層学習を用いて人物のポーズを可視化してくれる手法である[8]。OpenPose は、静止画を入力するだけで人間の関節点を検出することが可能であり、さらに GPU などの高性能プロセッサを使用すれば動画像内に複数人の人物がいても、リアルタイムに検出することが可能ということで、注目を浴びている手法である。具体的には、まず画像から各関節位置を Deep Learning を用いて推定する。次に各関節毎に一枚の confidence map を求め、そしてそれらの関節を繋ぎ合わせることで人の市政情報を得ている。この時、繋ぎ合わせた関節が普通ではありえない方向にならないよう、画像から認識した関節をこの組み合わせの中から正しいものを推定するために用いられているのが、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 PAFs (Part Affinity Fields) と呼ばれる手法である。Openpose は映っている人数に関わらず一回の推論で 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も大きな特徴である。図 2 が 25 点の関節点を示した二次元画像であり、表 2 が 25 点の関節点の名称である。



s

図 2 : 25 点の関節点を示した二次元画像  
 ([6]Markerless camera-based vertical jump height measurement using  
 OpenPose より引用)

表 2：図 2 の関節の番号の説明

関節 ID	0	1	2	3	4	5	6	7	8
説明	鼻	首	右肩	右肘	右手首	左肩	左肘	左手首	腰中央
関節 ID	9	10	11	12	13	14	15	16	17
説明	右腰	右膝	右足首	左腰	左膝	左足首	右目	左目	右耳
関節 ID	18	19	20	21	22	23	24	25	
説明	左耳	左つま先(根元)	左つま先(指先)	左かかと	右つま先(根元)	右つま先(指先)	右かかと	背景	

このような関節データの抽出は従来ではモーションキャプチャーという技術を活用することで行うことができた。この技術も **OpenPose** と同じように、関節の位置から姿勢データを抽出することができる。モーションキャプチャーのキャプチャー技術は光学式、慣性式などの方式が存在し、例えば光学式は複数台のカメラを使用してマーカーの位置をトラッキングする方式であり、位置精度が高くマーカーをつけることで人や物をキャプチャーすることができるので現在最も幅広い分野で活用されている。活用例としては、その位置精度の高さからハリウッド映画の **CG** 制作などの要求の高い現場ややハイクオリティな **Vtuber** などに用いられている。また、画像認識の既存の方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だった。しかし、モーションキャプチャーのこれらの方式は人や物にマーカーを取り付ける必要があり、複数台のカメラを用いなければならない場合が多い。また、従来の画像認識では、バウンディングボックス内に一つの物体しか存在しない場合ならバウンディングボックスの発見といった手法でいいが、一度に複数の物体を認識する場合はその

手法は使用することができない．それに比べて **OpenPose** では特別な機材を準備する必要がなく，撮影するカメラも 1 台で複雑な動作も解析することができる．複数台のカメラを用いて撮影する場合，スクラムを組む上で重要な関節である関節データをうまく抽出できないカメラがある場合がある．そのためカメラ 1 台で関節データの抽出を行うことができる．これらの理由から本研究では，**OpenPose** を用いる．図 3 はモーションキャプチャーによる動作解析を用いた模倣ロボットの例，図 4 は複数人で撮影した場合の関節の座標を表している．



図 3：モーションキャプチャーによる動作解析を用いた模倣ロボットの例  
 ([7]モーションキャプチャーによる全身運動解析と模倣ロボット - 「じょんがら」節を HRP-1S に踊らせる -より引用)



図 4：複数人で撮影した場合の関節の座標

## 第3章 スクラムの優位性判定モデル

本章では、ラグビーのスクラムの優位性予測モデルの構築について説明していく。近年ではラグビーワールドカップの国内開催によって、国内でのラグビーの注目度は以前に比べて確実に高まってきている。しかし、ラグビーは野球やサッカーなどのメジャースポーツに比べてマイナースポーツであることや、虚偽人口の少なさにより、経験者はラグビーに力を入れている私立高校に集中するようになり、公立高校では部員が思うように集まらなくなっている。そのため、練習を行うのに多くの人数を必要とするスクラムというプレーは公立高校の選手にとって練習しづらいプレーになってきている。また、公立高校では指導者が未経験者や経験者であってもFWのポジションを経験したことがないような指導者が数多くいるため、満足な練習ができていないのが現実である。そこで、私は指導者がいない公立高校でも満足な練習が行えるようにこのスクラムの優位性予測モデルを構築したいと考えた。以下では、ラグビーのスクラムの説明から、どのように構築し、どのような精度が出たのかを述べる。

### 3.1 モデル構築の概要

本節では、スクラムの優位性予測モデルの構築の流れについて説明する。まず、予測モデルを構築するにあたって最初に必要な作業が学習に使用するためのデータの収集である。今回は1v1のスクラムを撮影し、OpenPoseを用いて関節データを抽出することでデータを収集し、データセットを作成した。次にデータの入力である。MLPには入力層、中間層（隠れ層）、出力層がある。入力層ではデータセットの入力、中間層（隠れ層）では重みを更新することでこの層でのグループ分けを次の層で生かすことができる。入力層では抽出した25個の関節のX座標とY座標とその関節の信頼度を、中間層（隠れ層）ではノード数は512に、活性化関数は正規化線形関数を用い、過学習を防ぐことができるドロップアウト比率は0.2と設定した。出力層ではノード数を2に設定し、活性化関数はソフトマックス関数、ドロップアウト比率は0.2と設定した。そして、学習過程の設定やバッチサイズ、学習の繰り返し回数を設定することで学習させることができる。これらの流れによってモデルを作成することができる。



## 3.2 姿勢データの収集

スクラムの優位性予測モデルを構築するにあたって、スクラムの学習データとしてスクラムの姿勢データを収集する必要がある。そのために、本研究では立命館大学体育会ラグビー部の O 君と K 君に協力してもらい、横から撮影したスクラムの動画を 50 ほど撮影した。スクラムに関しては、正規の人数である 8 人と 8 人で撮影した場合、図 1 のように 16 人がタイトに組み合っているため、移っていない関節が多く、私が一番欲しいと考えている前 1 列の選手の関節データがほとんどうまく取れていなかった。そのため、本研究で扱うスクラムの動画は練習をするにあたって一番基本的なスクラムである 1 人と 1 人の 2 人で行うスクラムを撮影した。今回撮影した 50 本のスクラムの動画は左側の選手に重点を置き、前進することができたら○と示し、後退してしまったら×と示すというようにスクラムの可否を記録した。

表 3 : 50 本のスクラムの結果

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
○	×	○	×	○	×	○	×	○	×

### 3.2.1 画像から姿勢データの抽出

上記で記述した 50 本の動画をスクラムの優位性予測モデルの学習で使用できるようにするため姿勢データに変換する必要がある。まずは、50 件のスクラムの動画を、OpenPose を用いて 25 点の関節点を抽出し、50 件の json データを抽出した。動画はフレーム数という画像のコマ割りみたいなものであり、そのフレームごとに 1 つずつ json データが生成される。したがって、1 つの json データは 1 枚の画像から抽出した json データということになる。MLP で使用するのには動画ではなく、画像データでの姿勢データであるので、動画から作成した 50 件の json データから必要な分のフレーム数の json データを抜き出せばよい。

### 3.3 MLPによるモデル構築

本研究では、スクラムの優位性予測モデルを構築するためにディープラーニングの分野において用いられるニューラルネットワークの1つである MLP を用いた。まず、ディープラーニングとは人間が自然に行うタスクをコンピュータに学習させる機械学習の手法の1つであり、ニューラルネットワークがベースとなっている。また、ニューラルネットワークを多層にし、用いることでデータに含まれる特徴を段階的により深く学習することが可能となる。そして、MLP とは、多層パーセプトロン (Multilayer perceptron) の略であり、1986年にアメリカの認知心理学者のデビッド・ラメルハートが誤差逆伝番法を考案し、注目された順伝播型ニューラルネットワークの1つである。MLP は少なくとも3つのノードからなる。以前では、多層パーセプトロンは単純パーセプトロンのように直接誤差を計算することは不可能であったが、誤差逆伝番法を使用することにより多層パーセプトロンでも重みを学習することが可能になった。この手法が提唱されてからディープラーニングの精度は極めて高いものとなり、時には人間の認識を超える場合も出てくるようになり、その精度の高さから MLP が第3次 AI ブームの火付け役となった。MLP は様々な分野で活用されており、例えば、有明海の大潮時と小潮時の塩素量を、多層パーセプトロンを用いて学習させることによって河川感潮域の塩素量解析を行うことができる[3]。その他にも、LP ガスの使用量と気温の関係性から多層パーセプトロンを用いて、利用者をいくつかのタイプに分類したり、多層パーセプトロンを用いて肺がんの画像診断を行うなど様々な分野で用いられている[4], [5]。

MLP の特徴は、複雑な問題を解ける点である。MLP の学習では誤差逆伝番法 (バックプロパゲーション) を用いて行う。この方法は入力データに対して、最初に重みを設定して、出力データを作成する。その出力データに対して、入力データを与え、入力データとの誤差が最小になるように各重みの値を少しずつ増減することによって調整を行う。そして、この調整を繰り返すことによって、データをうまく分類できるようになる。この方法により、あらゆるデータに対して、機械学習を行えるようになった。また、MLP (多層パーセプトロン) と単純パーセプトロンの違いは多層かどうかの差である。単純パーセプトロンは複数の入力に対して、出力は単一になるパーセプトロンのことであり、MLP にあった中間層が存在しない。そのため、単純パーセプトロンは 0 か 1 かのどちらかしか表現できない。そのため、線形などの単純な分類は単純パーセプトロン、それ以外

の非線形分類問題などには **MLP** が用いられる.




図 5 : MLP(多層パーセプトロン)の例

## 第4章 スクラムの姿勢改善

第1章でも述べたが、近年ラグビーワールドカップの国内開催の影響で、国内でのラグビーの注目度は高くなっている。近年では選手が練習や試合中に GPS を装着し、走行距離やスプリント回数などを計測したり、練習や試合の様子をドローンを用いて撮影し真上から試合の分析を行えたりなど IT 技術を練習に取り入れているチームは少なくない。ラグビーのスクラムというプレーもドローンで撮影することで、スクラムのベクトルなどを確認するなど IT 技術を積極的に用いてパフォーマンスの向上を図っている。しかし、公立高校などの小さなチームでは指導者がスクラムの専門的な知識を持っておらず、スクラムの指導を満足に行えていないのが現状である。そこで、現状の指導方法や現役の選手たちの知識を参考に、スクラムの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、特定の専門分野や業界についての知識や知見のことである。本節では、ラグビーのスクラムについてのドメイン知識について、現状の指導方法や選手意見も交えながら説明していく。

#### 4.1.1 指導内容

本節では、本研究で用いたラグビーのスクラムにおけるドメイン知識を決定する上で、参考にした指導内容である。この指導内容は元ラグビー日本代表の中林正一からお聞きしたものである。中林は現役時代スクラムの中心で相手と組みあうフッカーというポジションで主にプレーしており、ヤマハ発動機ジュビロ(現静岡ブルーレヴズ)では 2001 年から 2007 年の間所属し、その間に日本代表キャップを 4 キャップ獲得している日本有数のラグビープレーヤーである。その後、2011 年に立命館大学体育会ラグビー部の監督に就任し、現在はコーチとして立命館大学体育会ラグビー部を指導している。中林からお聞きした指導方法について説明していく。今回はスクラムにおける前 1 列、いわゆるフロントローの指導方法についてお聞きした。中林はスクラムにおけるフロントローの役割はスクラムの第 2 列、第 3 列の選手の推進力をいかに相手に伝えるかがフロントローの仕事だとお聞きした。スクラムを組む際に有利になるような関節の位置に関節を持っていくことがスクラムを押すうえで 1 番重要である。その中でも、特に重要な関節は股関節、椎間関節、足首の関節であり、これらの関節が

スクラムを押すために最適な角度で組めるような技術を身に着けることがパフォーマンスの向上に繋がるのが今回お聞きした中林の指導内容である。

#### 4.1.2 選手に対するアンケート

ラグビーのスクラム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一部のスクラムの専門的知識を有するフロントローの選手 11 名に「スクラムを組む時に意識している関節を 3 つ挙げるとすればどの関節か」というアンケートを取った。アンケートをまとめた円グラフは図 8、アンケートの数値をまとめた表は表 3 で示している。このアンケートの対象である 11 人の多くは股関節が重要な関節だと答えた。次に、背中が 8 人、膝が 7 人と過半数の選手がこの 3 つの関節が重要だと答えた。この 3 つの関節の 2 つは中林が提示したスクラムにおける重要な関節と共通している。したがって、股関節と背中の関節はスクラムにおけるドメイン知識の関節だと言える。また、足首は中林が重要な関節だと答え、このアンケートの対象者である 11 人中 7 人が重要な関節だと答えた。したがって、足首の関節と膝の関節はスクラムにおけるドメイン知識の関節だと言える。よって、股関節、背中、膝、足首の関節がスクラムにおけるドメイン知識の関節だと言える。




図 6：重要な関節のアンケートの集計結果の円グラフ

## 4.2 改善方法

本章の第1節でも述べたが、股関節、背中、膝、足首の関節がスクラムにおけるドメイン知識の関節だと予想した。したがって、これらの関節のデータだけを抽出し、それらの関節データのみでスクラムの優位性予測モデルを作成し、全姿勢データで作成したスクラムの優位性予測モデルの結果と比較し、それらの関節が本当にスクラムにおけるドメイン知識の関節だと言えるのかを検証する。また、テストデータの中の優位性がないスクラムのデータのスクラムにおけるドメイン知識だと言える関節の X 座標と Y 座標を最適な角度と言われる角度に変更し、そのデータを予測モデルで予測し、優位性があると判定されるような姿勢を発見する。

## 第5章 実験

本章では、全関節データを用いたスクラムの優位性予測モデルの実験の結果とドメイン知識の関節と予想した関節データのみを使用した予測モデルの実験の結果について説明する。

### 5.1 全関節を用いたモデルの予測精度

本研究では、3.2でも述べたように1v1のスクラムの動画を50本撮影した。しかし、今回作成したモデルは画像を用いて学習するモデルのため、動画から必要なデータを抜き出す作業が必要である。そのため、撮影した動画を、OpenPoseを用いてフレームごとに関節のデータを抽出し、動画につき2フレームを動画ごとに抜き出し、100件のデータが入ったデータセットを作成した。また、テスト用の動画を10本撮影し、学習用のデータセット同様に2フレームずつランダムに抜き出し、20件のデータが入ったデータセットを作成した。それらを用いたモデルの精度を検証した。予測モデルの精度を測る際、ニューラルネットワークの重みの初期値をランダムに割り当てるため、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。精度の平均の結果は50%となった。そのため、精度の向上を図るために、100件の関節のデータを一定の距離を平行移動させ、200, 400, 1000, 2000, 4000件とデータを拡充した。それらのデータを用いて精度の検証を行った。しかし、精度は40%を切ることもあり、精度は向上しなかった。

表4：各データ数の予測精度

データ数	100	200	400	1000	2000	4000
精度	50%	46%	45%	41%	40%	38%

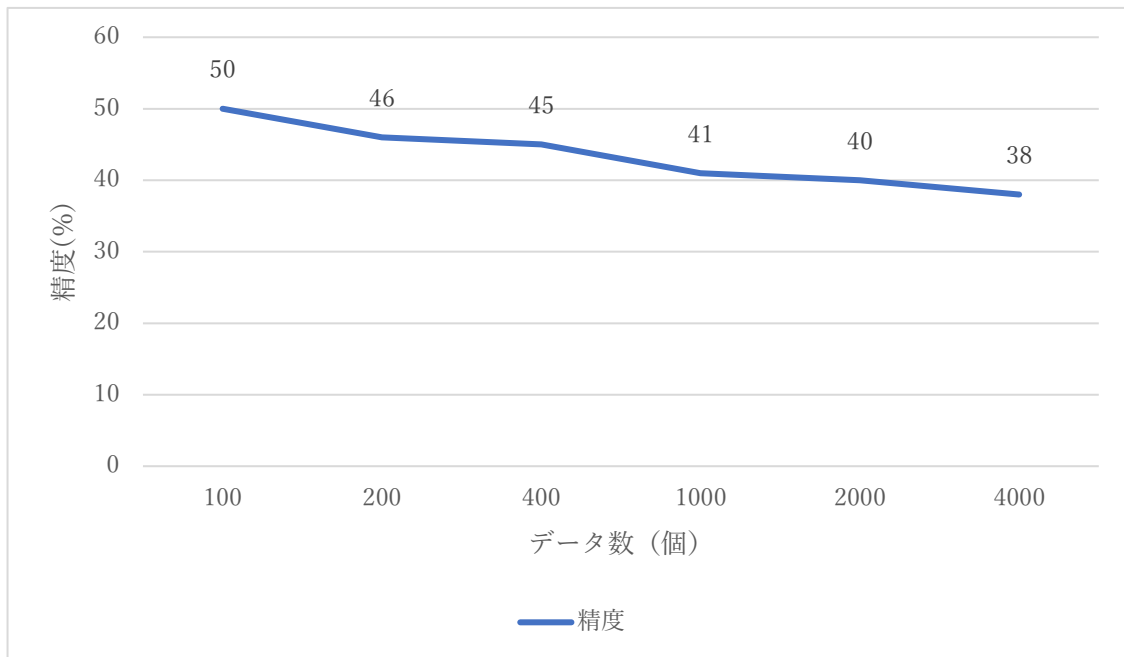


図 7: 各データ数の予測精度の折れ線グラフ

## 5.2 ドメイン知識を用いたモデルの予測精度

スクラムを指導する際、意識する関節が多すぎると選手が理解しづらいことや、第 4 章で紹介した調査したアンケートの結果とラグビー界でトップクラスの指導者である中林さんがお話を聞いた重要な関節で共通して重要だとされる関節があることからドメイン知識の関節を腰、股関節、膝、足首の関節と仮定して、それらの関節のデータを抽出した。今回の研究で用いたデータは K 君の右側から撮影しているため、第 2 章の図 2, 表 2 で示してある 8 の腰中央, 9 の右腰, 10 の右膝, 11 右足首の計 4 カ所の関節を抽出した。前節でも述べたが、データを拡充するとノイズが多くなり精度が向上しなかったためドメイン知識の関節を用いた予測モデルでは 100 件のデータのデータで予測を行った。予測精度の平均は 60% を達成し、100 件のデータの全関節を用いた予測モデルと比較すると、約 10% 精度が向上した。






図 8 : 全関節とドメイン知識の関節のモデルの比較

また、スクラムが前進しているテストデータのドメイン知識の関節データを比較すると、**80%**が腰と膝の X 座標が $\pm 10$ しか値が変わらなかった。そのため、腰と膝の X 座標を等しくするとスクラムは前進すると仮定し、スクラムが後退するテストデータのドメイン知識の関節データを腰と膝の X 座標が等しくなるように変更した。そして、スクラムが後退しているテストデータのドメイン知識の関節データのみを用いて、関節の数値を変更する前のテストデータと変更した後のテストデータで予測を行った。変更する前のテストデータを用いた予測モデルが前進すると判断したときの精度は **20%**となったが、変更した後のテストデータを用いた予測モデルが前進すると判断したときの精度は **80%**を達成し、精度が **60%**向上した。この結果から、腰と膝の X 座標を等しくなるような姿勢はスクラムを前進の確率を高めるような姿勢だということがわかる。また、この改善案は既存の改善案で存在しており、この結果から、この改善案の妥当性を予測モデルを用いて検証することができた。




図 9 : ドメイン知識の関節データを変更する前と変更した後の予測モデルの比較

### 5.3 スクラムの改善案の妥当性

前節でも述べたが、既存の改善案である腰と膝の X 座標を等しくなるような姿勢が前進する確率を高めるという改善案の妥当性が検証された。さらに、腰と膝の X 座標を等しくなるような姿勢が前進する確率を高める姿勢というスクラムの改善案の妥当性を検証するために、立命館大学体育会ラグビー部のスクラムの専門的知識を有するフロントローの選手 11 人に図 10 と図 11 の 2 枚の画像を見せ「どちらがスクラムを押しことができる姿勢の画像か」というアンケートを実施した。その結果、全員が図 10 のスクラムが前進しているテストデータの画像を選択した。このアンケートの結果から腰と膝の X 座標を等しくなるような姿勢が前進する確率を高める姿勢というスクラムの改善案は妥当性があるとわかった。



図 10 : 前進しているテストデータの画像



図 11 : 後退しているテストデータの画像

## 第6章 考察

第5章で全姿勢データから MLP を用いてスクラムの優位性予測モデルを作成し、予測モデルの精度を 100, 200, 400, 1000, 2000, 4000 のそれぞれのデータ数で精度を比較した。同様に中林さんの指導内容や、選手に対するアンケートの結果を基に、スクラムにおけるドメイン知識の関節を選択し、それらの関節の座標を入力し学習させ、全関節の予測モデルとドメイン知識の関節の予測モデルの精度を比較し、スクラムにおけるドメイン知識の関節の有用性について検証した。全関節を用いた予測モデルの精度は 100 件のデータを平行移動させることでデータを拡充し、拡充したデータで予測精度を検証したが、スクラムの優位性を予測するのに必要ではない関節のデータやうまくデータを抽出することができなかった関節のデータがデータを拡充するほど増えてしまったので、データ数を増やすほど精度が落ちてしまったと考えられる。そのため、比較するデータの数は両方ともに 100 件のデータを学習データとして用いて予測精度を比較した。全関節のデータを用いた予測モデルの精度は 50%に対して、ドメイン知識の関節データを用いた予測モデルの精度は 60%を達成し、全関節データを用いた予測モデルの精度と比較すると精度が10%向上しているのがわかった。したがって、ドメイン知識の関節として用いた腰、股関節、膝、足首の関節はスクラムの優位性において重要な関節だと検証された。

次に、スクラムの優位性において有用な関節の角度を探索するために、テストデータの前進するスクラムのドメイン知識の関節データの共通点を探索したところ、前進するスクラムのドメイン知識の関節データの腰と膝の X 座標の値が、10 件中 8 件が $\pm 10$ 以内に収まっているという共通点を発見した。そこで、テストデータの後退するスクラムのドメイン知識の関節データを腰と膝の関節データの X 座標の値が等しくなるように変更し、テストデータを変更する前の後退するスクラムのドメイン知識の関節データと変更した後の後退するスクラムのドメイン知識の関節データの 2 種類に設定し、予測モデルの精度を比較した。変更する前の関節データの予測モデルが前進すると判断したときの割合は 20%だったのに対し、変更した後の関節データの予測モデルが前進すると判断した割合は 80%を達成し、変更する前の関節データの予測モデルと変更した後の予測モデルの前進と判断した割合を比較すると割合が 60%向上していることがわかった。したがって、既存の改善案である腰と膝の X 座標を等しくなるような姿

勢はスクラムを前進の確率を高めるような姿勢の妥当性が検証された。さらに、既存のスクラムの改善案の妥当性を検証するために、立命館大学体育会ラグビー一部のスクラムの専門的知識を有するフロントローの選手 11 人に図 10 と図 11 の 2 枚の画像を見せ「どちらがスクラムを押すことができる姿勢の画像か」というアンケートを実施したところ、全員が図 10 の前進するスクラムのテストデータの画像を選択した。このアンケートの結果からスクラムの改善案の妥当性が検証された。

これらの結果から、既存のスクラムの改善案である腰と膝の X 座標が等しくなるようなスクラムにおけるドメイン知識の関節の角度が、スクラムが前進する確率を高める角度というスクラムの指導案が有用だと検証された。

## 第7章 おわりに

本研究では OpenPose を用いて、スクラムデータから関節データを抽出し、MLP を用いて学習をする事でラグビーのスクラムの優位性予測モデルを構築した。全関節のデータを用いた 100 件のデータを用いた場合と 100 件のデータを拡充したデータを用いた場合の予測モデルを比較すると、拡充したデータの場合はデータを拡充すればするほどノイズも増えてしまったため、精度は向上しなかった。また全関節のデータを用いた関節データを用いた予測モデルとスクラムのドメイン知識の関節を用いた予測モデルを比較するとドメイン知識の関節の関節データを用いた予測モデルは学習するためのデータにノイズが全関節のデータを用いた予測モデルに比べて少ないため、精度が 10%向上した。したがって、撮影した画像の関節データの中から必要な関節データのみを学習データに入れていくことでノイズが少ないデータを学習データに入れることができるため、より精密な予測モデルを構築できると考えられる。この予測モデルは指導者不足や人数不足で満足な環境で練習できていない選手にとっては、これまでより実践的な練習ができると考えられる。

また、本研究では改善案の妥当性を検証するために、テストデータの分析を行い、前進するスクラムの関節データには腰と膝の X 座標の値が $\pm 10$ しか変わらないという共通点を発見し、その共通点を基に後退するスクラムのデータのドメイン知識の関節データを変更し、変更する前のデータと比較を行った。変更する前のデータは前進すると判断したときに精度は 20%だったが、変更したデータは前進すると判断したときに精度は 80%を達成し、この結果から既存の改善案である腰と膝の X 座標の値が等しくなるようなスクラムの姿勢の妥当性を検証した。さらにその改善案の妥当性を検証するために、立命館大学体育会ラグビー部のスクラムの専門的知識を有するフロントローの選手 11 人にアンケートを行い、アンケートの結果からこの改善案はスクラムの指導において有用であると検証された。

本研究では 1v1 のスクラムを横から撮影し、そのデータを用いて研究を行ったため、スクラムを組む上で必要な他のポジションの選手や俯瞰視点から見たスクラムのベクトルは考慮していない。しかし、実際のスクラムでは 8v8 の計 16 人でスクラムを組むのでフロントロー以外の選手が原因でスクラムが押されてしまう場合がある。また、スクラムは横から見た姿勢だけではなく、スクラム

を押すベクトルも重要になってくるため、これらの条件を考慮してスクラムの優位性予測モデルを構築できれば、より実用的なモデルを構築できると考えられる。また、予測モデルに用いる関節を変更しモデルを構築することで、現在のラグビー界ではまだ知られていない重要な関節が発見できるかもしれない。

## 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准教授、ピタクスワンモンティージャー助教に深く御礼申し上げます。また、本研究のアンケートなどに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] 中井真人, 角田善彦, 孫財東, 村越英樹, 林久志, 綱代剛 : OpenPoseによるバスケットボール・フリースローの命中予測, 2018年度人工知能学会全国大会 (第32回), 第32回(2018).
- [2] 姜文淵, 山本雄平, 田中成典, 中村健二, 田中ちひろ : OpenPose によるフィールド全域画像からのサッカー選手の識別に関する基礎的研究, 第 35 回ファジィシステムシンポジウム講演論文集, 第 35 回(2019).
- [3] 平松和昭, 四ヶ所四男美, 森健 : 多層パーセプトロンモデルによる河川感潮域の塩素量解析, 農業土木学会論文集, 1995 巻, 178 号, pp.483-492,a2 (1995).
- [4] 許慎碩, 村上英治, 高橋大志 : 日本のガス使用量における決定要因に関する研究 -多層パーセプトロンモデルによる分析-, 経営課題にAIを!ビジネスインフォマティクス研究会 (第18回) , 2021巻, BI-018号, pp.14(2021).
- [5] 木戸尚治 : 肺癌の画像診断における AI の現状と可能性, 2021 日本肺癌学会, 61 巻, 4 号, pp.282-288(2021).
- [6] Webering, F., Blume, H., Allaham, I. : Markerless camera-based vertical jump height measurement using OpenPose, in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR) Workshops*, pp. 3868-3874(2021)
- [7] 中澤篤志, 中岡慎一郎, 白鳥貴亮, 工藤俊亮, 池内克史 : モーションキャプチャによる全身運動解析と模倣ロボット - 「じよんがら」節をHRP-1Sに踊らせる -, 情報処理学会研究報告コンピュータビジョンとイメージメディア (CVIM), 2004巻, 113(2004-CVIM-146)号, pp.31-39(2004).
- [8] Cao, Z., Simon, T., Wei, S. E., and Sheikh, Y.: Realtime Multi-person 2d Pose Estimation Using Part Affinity Fields, in *proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.7291-7299(2017).