

卒業論文

LSTM を用いたラグビーのゴールキック予測 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
2600180100-6

木田 晴斗

2021 年度（秋学期）卒業研究 3（CH）

令和 4 年 1 月 31 日

LSTM を用いたラグビーのゴールキック予測モデル

木田 晴斗

内容梗概

近年、日本でラグビーワールドカップが開催されたことで、ラグビーの強化が加速している。特に、スクラムはドローンなどのカメラを駆使し、相手を押し切る姿勢や組み方の分析が進んでいる。一方で、得点に直結するゴールキックは、ラグビーのプレーの中で最も繊細であり、選手個人によってフォームが異なるための確な指導が難しい。この課題に向けて、ラグビー界ではゴールキック専門のコーチとして活動する人も現れてきた。しかしながら、ラグビーのゴールキックは人によって自分に合ったフォームが異なるため、ゴールキック専門コーチがその人にあった指導をすることは難しい。また、日本ではゴールポストが設置されている場所も少ないため、ゴールポストが使えない選手達は実践的なキック練習をできる機会が少なく、ゴールキックの練習量が不十分である。

そこで、本研究ではゴールキックの動画から LSTM を用いてゴール予測モデルを生成し、ゴールを入れるのに重要な要素となる関節を特定する。具体的には、ゴールキックの動画から OpenPose を用いて姿勢データを取得し、姿勢データとゴールキックの位置データを入力データ、ゴールの有無を教師信号として学習を行う。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。

姿勢データの拡充

ゴール予測モデルを構築するには、大量かつ多様なゴールキックの姿勢データが必要である。特に、ゴールキックはサッカーのペナルティーキックと異なり、トライした場所によって、ゴールキックを行う場所が変わるため、蹴る位置の異なるデータが必要となり、大量のデータを収集することが困難である。

ゴール予測に有用な関節データの検証

キックに全く必要ではない関節があると考えられるため、ゴール予測に有用な関節を抽出する必要がある。そして、ラグビーのドメイン知識で重要と考えられている関節が実は重要な関節ではないかもしれない。選手達により正確な指導をするためにも、必要十分な関節を検証する。

一つ目の課題には、ディフェンスに防御されにくく、最も近い位置である、

22m ライン上でシーズデータを収集し、そのデータの位置座標を並行移動させることで、データの拡充を行った。具体的には、右利きの選手から 22m ライン上で、ゴールポストに対して右左斜め 50 度 13 本ずつ、正面 8 本、右左 40 度 8 本ずつで代表的な 5 種類の位置で計 50 本のゴールキックの姿勢データを収集した。その姿勢データの座標をランダムに選択した距離だけ並行移動し、データ数を 50 件から 4000 件に増加させて、ゴール予測モデルを構築した。

二つ目の課題には、異なる関節を対象とした二種類の姿勢データから LSTM を用いてゴール予測モデルを生成し、予測モデルの精度を比較することで、ゴールを入れるのに重要な要素となる関節を特定する。具体的には、ラグビーのドメイン知識に基づいて選択した両目、両肩、蹴る足の右膝、蹴る足の右足首のデータ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とで二種類のゴール予測モデルを構築した。次に、両者のモデルを用いてゴール予測を行い、Accuracy によって二つのモデルを評価し、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。

姿勢データの拡充

代表的なゴールキック位置を 5 箇所選択し、50 件の姿勢データを収集した。その姿勢データの関節の座標を並行移動して、100, 500, 1000, 2000, 4000 件に学習データを拡充することで、50 件の学習と比較して最大約 26%程度 Accuracy を向上させることができた。

ゴール予測に有用な関節データの検証

ドメイン知識に基づいて選択した関節を対象とした姿勢データと、全関節を対象とした姿勢データを用いてゴール予測モデルを構築し、Accuracy の比較を行った。実験の結果、ドメイン知識に基づくモデルが全関節データを用いたモデルと同程度の精度であったことから、ドメイン知識である、両目、両肩、蹴る足の右膝、蹴る足の右足首の位置がゴールキックの成功の可否に重要な要因であることが検証された。

Rugby Goal Kick Prediction Model Using LSTM

Haruto Kida

Abstract

A few years ago, the Rugby World Cup was held in Japan, and various technologies were, and are, applied to the training for rugby. In Scrum training, cameras such as drones and videos are used to analyze the posture and assembling of scrums that can push away the opponent. Although the goal kick, which is directly linked to the score, is the most delicate play in rugby, it's difficult to give precise instructions because each player's form is different. Some people have been working as goal kick coaches to help with this task. However, each person's rugby goal kicks take on a different shape. It is difficult for a goal kick specialist coach to provide advice that is appropriate for individuals. In addition, there are only a few places in Japan where rugby goal posts are installed, so that athletes who do not have access to a goal post have limited opportunities to practice practical kicks, and goal kick practice is insufficient.

Therefore, we use LSTM to generate a goal prediction model from a video of a goal kick and to identify the appropriate application of which joints (knees, ankles, elbows, etc.) are important factors for scoring. In this study, OpenPose was used to collect posture data from goal kick videos; the posture and position data of the goal kicks were input, and the presence or absence of the goal was used as a supervisory signal for learning. To this end, we addressed the following two issues.

Expansion of posture data:

A large amount of diverse goal kick posture data is required to build a goal prediction model. Goal kicks, unlike penalty kicks in soccer, necessitate different kick position data because the location of the goal kick is dependent on where the goals are attempted, and, thus, large amounts of data are difficult to collect.

Verification of joint data for goal prediction:

Some joints are thought to be unnecessary for kicking, it is necessary to extract joints that are useful for goal prediction. Furthermore, the joints that are considered important in rugby domain knowledge may not be important joints at all. This study verified the necessary and sufficient joints in use for kicks to provide more accurate guidance to athletes.

For the first task, we collected the seed data on the 22m line which is difficult to protect by defense and the closest position to the goal post, and expanded the data by shifting the coordinate positions in parallel. Specifically, on the 22m line from the right-handed player, there are 13 kicks each from both right and left side at an angle of 50 degrees, 8 kicks at the front, and 8 kicks from both right and left side at an angle of 40 degrees, for a total of 50 goal kick posture data were collected at five typical positions. A goal prediction model was constructed by moving the coordinates of the posture data in parallel by a randomly selected distance and increasing the numbers of data from 50 to 4000.

The second task was to use LSTM to create a goal prediction model from two types of posture data for various joints, compare the accuracy of predictive models, and to identify the joints that are important in scoring a goal. Specifically, two types of goal prediction models were built, one for learning using all joint data and other is selected based on domain knowledge of rugby, which are data of both eyes, both shoulders, right knee of the kicking foot, and right ankle of the kicking foot, which are selected based on the domain knowledge of rugby. The validity of the model constructed based on domain knowledge was then verified, and goal prediction was performed using both models. The two models were then evaluated by accuracy, and the validity of the model constructed based on domain knowledge was verified. The following are the research's contributions:

Expansion of posture data:

By selecting five typical goal kick positions, 50 posture data were collected. The accuracy can be improved by about 26% by translating the coordinates of the joints in the posture data and expanding the learning data to 100, 500, 1000, 2000, 4000 cases, as opposed to each of the 50 cases.

Verification of joint data useful for goal prediction:

The accuracy of a goal prediction model that was built using posture data for joints chosen based on domain knowledge and posture data for all joints was compared. The model based on domain knowledge was as accurate as the model using all joint data as a result of the experiment. The domain knowledge position, both eyes, both shoulders, right knee of the kicking foot, and right ankle of the kicking foot were all verified to be important factors in the goal kick's success.

LSTM を用いたゴールキック予測モデル

目次

第 1 章	はじめに	1
第 2 章	姿勢推定を用いたスポーツ支援	3
2.1	姿勢推定手法	3
2.1.1	Openpose	3
2.2	関連研究	6
2.3	ラグビーのゴールキックとは	6
2.3.1	ゴールキックのルール	7
2.3.2	ゴールポスト	8
第 3 章	ゴール予測モデル	10
3.1	姿勢データの収集	10
3.1.1	動画から姿勢データの抽出	11
3.1.2	データの拡充	12
3.2	LSTM によるモデル構築	12
3.2.1	RNN	13
3.2.2	LSTM ネットワーク	14
3.3	全姿勢データを用いたモデルの予測精度	15
第 4 章	ドメイン知識に基づくモデル構築	17
4.1	ドメイン知識	17
4.1.1	指導内容	17
4.1.2	選手に対するアンケート	20
4.2	ドメイン知識を用いたモデルの予測精度	21
第 5 章	考察	23
第 6 章	おわりに	25
	謝辞	26
	参考文献	27

第1章 はじめに

近年、日本でラグビーワールドカップが開催されたことで、ラグビーの強化が加速している。大学やプロのチームでは選手に GPS をつけることで、選手の走行距離や、加速減速からプレー状況を把握している。これらは選手の疲労を管理する事に有効であり、パフォーマンスの向上にも繋がっている。その他にラグビーの醍醐味でもあるスクラムではドローンなどのカメラを駆使し、多様な角度で撮影することで、相手を押し切る姿勢や組み方の分析が進んでいる。一方で、得点に直結するゴールキック（第3章 3.1 で記述）は、ラグビーのプレーの中で最も繊細であり、選手個人によってフォームが異なるための確な指導が難しい。2015年ラグビーワールドカップで当時ゴールキッカーであった五郎丸歩がキックの前に行う「ルーティン」である「五郎丸ポーズ」をした事から世の中では流行語大賞の候補に入る程、有名になった。このようにプロの選手であってもルーティンを作る程に繊細なプレーなのである。この課題に向けて、ラグビー界ではゴールキック専門のコーチとして活動する人も現れてきた。しかしながら、ラグビーのゴールキックは人によって自分に合ったフォームが異なるため、ゴールキック専門コーチがその人にあつた指導をすることは難しい。指導者達は自分の感覚や経験、基本的なアドバイスをその選手にとって適切な指導なのかは明らかでない。また、日本ではゴールポストが設置されている場所も少ないため、ゴールポストがない選手達は実践的なキック練習をできる機会が少なく、ゴールキックの練習量が不十分である。

関連研究として Openpose を用いて、初心者からアマチュアのサッカー選手のシュートシーンの姿勢に着目し、自動でプレイを評価するシステムを構築するものがあつた。Openpose を用いて姿勢に着目するという点では共通している。しかし、上記にも書いたようにラグビーは人によってフォームが特に異なるため、他選手とキックの姿勢を比較することはできないと考える。

そこで、本研究ではゴールキックの動画から Openpose により姿勢データを収集し、LSTM を用いてゴール予測モデルを生成し、ゴールを入れるのに重要な要素となる関節を特定する。本研究では立命館大学体育会ラグビー部の M 君のゴールキック動画を使用し、ゴール予測モデルを生成した。このモデルは M 君のゴール予測を可能とするものである。つまり、このゴール予測モデルは学習に使用した動画のキッカーに対する予測が可能なモデルである。本研究では、

ゴールポストのない場所でのゴールキックの動画からゴールの可否を予測することで、ゴールキックの実践的な練習量を増加する事。また、ゴールキックの指導内容の現状が正しいのかどうかを検証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。

姿勢データの拡充

ゴール予測モデルを構築するには、大量かつ多様なゴールキックの姿勢データが必要である。特に、ゴールキックはサッカーのペナルティーキックと異なり、トライした場所によって、ゴールキックを行う場所が変わるため、蹴る位置の異なるデータが必要となり、大量のデータを収集することが困難である。そのため、収集したゴールキックの姿勢データを拡充しなければならない。

ゴール予測に有用な関節データの検証

ゴール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、意識させる関節が多過ぎると難しい。また、ドメイン知識からキックに全く必要ではない関節があると考えられるため、ゴール予測に有用な関節を抽出する必要がある。そして、ラグビーのドメイン知識で重要と考えられている関節が実は重要な関節ではないかもしれない。選手達により正確な指導をするためにも、必要十分な関節を検証する。

以下本論文では、第2章では姿勢推定手法である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、そしてラグビーのゴールキックについて説明している。第3章ではゴール予測モデルの構築と学習データの比較を説明している。第4章ではドメイン知識に基づくモデルの構築に関し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章では第3章の精度と第4章の精度を比較し考察を記述。第6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支援

本章では、姿勢推定がスポーツにどのような関係があるのかを関連研究を交えながら説明する。また、本研究で用いた主な手法である Openpose について説明する。

2.1 姿勢推定手法

姿勢推定とは画像認識の分野であり、姿勢推定と呼ばれる技術は人物の写っている画像や動画から、人物の関節を取ることで姿勢についての情報を特定する推論アルゴリズムである[2]。近年、姿勢を推定するという技術は様々な職業で活用され、また、スポーツにおけるフォームの分析で使われていることは有名である。姿勢を推定するために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 Openpose やモーションキャプチャなどである。ただ、姿勢推定モデルを含めた画像認識分野の AI は学習のために必要なデータが非常に大きく、精度を上げることが非常に難しい。しかし、どのような AI モデルだったとしても精度が求められるように、画像認識の分野で求められるものは検出精度であるため、関節点などを抽出するような技術が非常に重要となる。そこで本研究ではカメラ一台で動画を取ることができる、Openpose を用いた。次に Openpose について詳しく説明する。

2.1.1 Openpose

OpenPose はカーネギーメロン大学の Zhe Cao らによって「Realtime Multi-Person pose estimation」の論文で発表した、深層学習を用いて人物の姿勢を可視化してくれる手法である。OpenPose は、動画や画像を入力データとする事で、それぞれの画角内に映される複数人物のポーズをほとんどリアルタイムで推定出来る姿勢推定ライブラリである。具体的には、カメラで撮影した画像や動画から 25 個の関節を抽出し、それらを点と線で示す姿勢推定モデルを表示できる。

(図 1) 25 点の 2 次元座標をキック動画の 1 フレームごとにファイルに出力する。本研究で使った動画の関節の座標をファイルとして出力したものが、図 2 である。

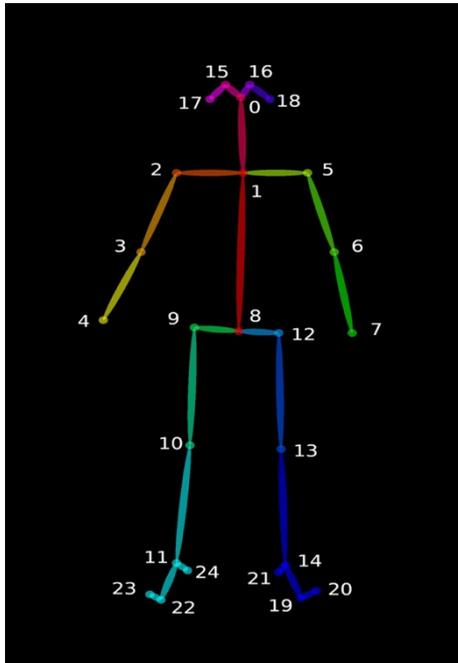


図 1 抽出される 25 点の関節

- {0, "Nose"},
- {1, "Neck"},
- {2, "RShoulder"},
- {3, "RElbow"},
- {4, "RWrist"},
- {5, "LShoulder"},
- {6, "LElbow"},
- {7, "LWrist"},
- {8, "MidHip"},
- {9, "RHip"},
- {10, "RKnee"},
- {11, "RAnkle"},
- {12, "LHip"},
- {13, "LKnee"},
- {14, "LAnkle"},
- {15, "REye"},
- {16, "LEye"},
- {17, "REar"},
- {18, "LEar"},
- {19, "LBigToe"},
- {20, "LSmallToe"},
- {21, "LHeel"},
- {22, "RBigToe"},
- {23, "RSmallToe"},
- {24, "RHeel"},
- {25, "Background"}

図 2 25 点の関節名

このような関節情報の取得は、これまでにモーションキャプチャという技術を使う事で可能であった。Openpose と同じように、関節の位置から姿勢を推定する事ができる。キャプチャ技術には光学式、慣性センサ式、機械式、磁気式などの方式があり、多くは人や物に装着するマーカーとこれを検出するトラッカーを組み合わせてキャプチャし、同じ方式を使えばマーカーの数が精度と繋がる。モーションキャプチャはスポーツ界で使われていることも多く、スポーツの動画解析ができ、指導やフォーム改善に役立っている。しかし、姿勢推定をするための関節の位置情報などを取得するために、身体にマーカーをつけたり、専用のスーツを装着しなければならない。また、様々な方向からカメラを設置するため、多くのカメラが必要となる (図 3)。それに比べて Openpose は特殊な設備が必要なく、カメラも一台で複雑な動作を解析できるため、非常に画期的な技術だと言える。特に、ラグビーのゴールキックを解析する場合には Openpose の方が適切だと考える。なぜなら、図 3 のようにカメラに囲まれてしまうと通常のプレー

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

環境と異なるため、キックの姿勢にも影響が出るのではないかと考えられるからである。Openpose の場合解析したい姿勢やフォームを横や前方の角度からカメラで取る事ができ、簡単に動画データを収集できる。図 4 はゴルフのフォームを横から撮ったもので、動画のフレームごとの関節の座標を表示している。図 5 は一つの写真の中に映る複数人の関節の座標を一度に表示している。



図 3 ¹モーションキャプチャのカメラ

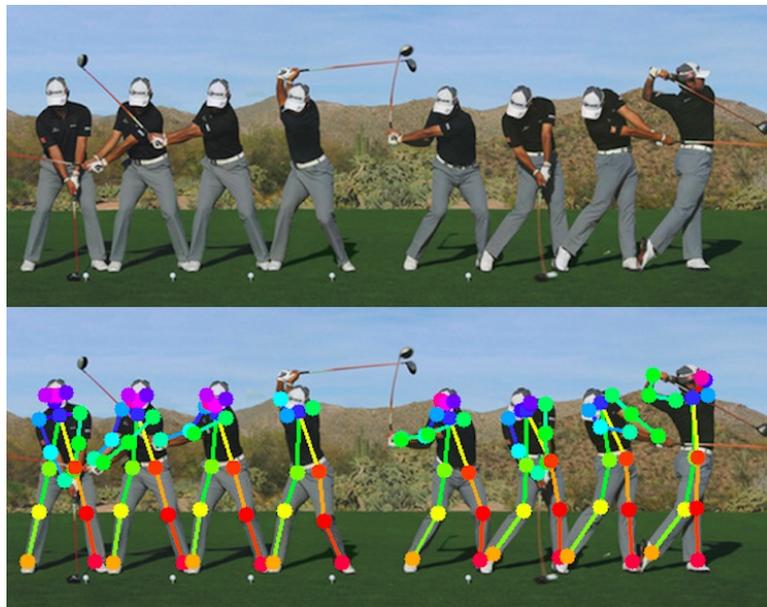


図 4² フレームごとの関節座標

¹ <https://mocap.jp/about-mocap/>

² <https://ledge.ai/openpose/>



図 5¹ 複数人の関節座標

2.2 関連研究

本節では Openpose を用いた関連研究を紹介する。金子らは[1]、本研究でも使用した Openpose を活用し、スポーツという共通点のあるサッカー界の発展に繋げる研究をしている。具体的に概要を説明する。まず、アマチュアスポーツ界ではパフォーマンスを簡単に分析できるような、プラットフォームが必要とされている。実際に、アマチュアサッカー界においても、所属するチームや指導者にかかわらず、誰でも上達できることを目指し、IT ツールを用いてトレーニングの向上や選手の評価を行う「Ertheo」というアプリが実用化されている。しかし、このアプリでは人間を手動での評価を前提としており、選手の映像から自動で評価することは困難である。そこで、この関連研究ではサッカー初心者からアマチュア選手のシュートシーンに着目し、自動でシュートを評価し、それを分類するシステムを構築している。Openpose で取得した姿勢の座標からドメイン知識に基づいて特徴量を生成し、決定木やロジスティック回帰などにより、分類可能かを分析した。特徴量の数値によって選手のレベルを分類し、実際の選手のレベルと比較することで、このシステムの accuracy を検証した。検証結果としてはシュート動画を分析することで、レベルを誤検出するものが1つあったが、シュートの質的評価をする事が出来たと言えた。

2.3 ラグビーのゴールキックとは

ラグビーのゴールキックはラグビーにおける得点方法の一つである。

¹ <https://ledge.ai/openpose/>

表1 ラグビーの得点

得点方法	得点
トライ	5点
コンバージョンキック	2点
ペナルティーゴール	3点

H ポールと呼ばれるゴールの上をキックによってボールが通ればゴールとなる。

(3.1.2を参照) 主な得点源であるゴールライン上にボールを置き得点する「トライ」後に毎回行うのである。正式には「コンバージョンキック」と呼ばれる。このゴールキックにはもう一つ行われる場面があり、それは「ペナルティーゴール」という。「ペナルティーゴール」は相手が反則をした際に選択できる得点方法である。得点などをまとめたものが表1である。表1の得点を見た時に、特にコンバージョンキックは2点と少なく見えるが「トライ」をする毎に行うため、「トライ」を重ねる毎に点は重ねられる。コンバージョンキックやペナルティーキックによって試合が決まることも多く、非常に重要なプレーである。

2.3.1 ゴールキックのルール

では、コンバージョンキックとペナルティキックのルールについて説明する。まず、コンバージョンキックは3.1でも述べたようにトライ後に毎回行うものである。そしてキックを行う場所はトライを取った(ボールを置いた)場所からサイドインに対し平行線上である。つまり、トライを真ん中ですればするほどゴールに対して真ん中になるため、成功率が上がる。その平行線上であればどこから蹴っても良いが、DFの15人はゴールライン上からキッカーに対してプレッシャーをかける事ができる。キッカーがキックモーションに入った瞬間からDFはゴールラインから走り出し、サッカーで例えればキーパーのように手でボールを叩くなどの行為をして良い。そのため、キッカーは自分のキックモーションの長さに応じて、プレッシャーを受けないある程度距離を取らなければならない。図6と図7を見れば真ん中でトライした場合と外側でトライした場合ではゴールに対して角度が全く異なることがわかる。

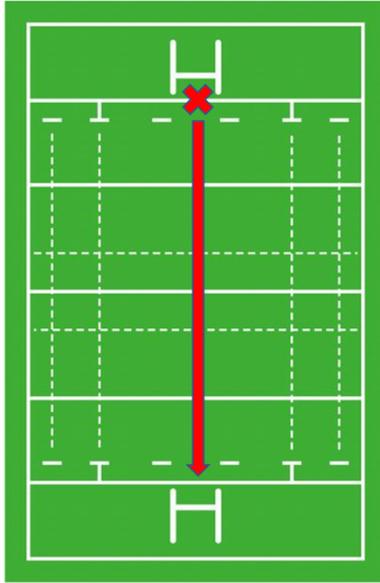


図 6¹ 真ん中にトライした場合

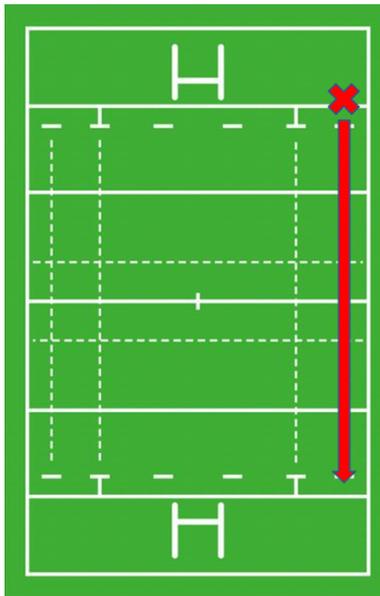


図 7² 5 m にトライした場合

2.3.2 ゴールポスト

地面に垂直に二本のポールがたっており、二本のポールを繋ぐようにクロスバーが地面から 3m の高さに設置されている。二本のポールの間の長さは 5.6m

¹ <https://brave-rugby.com/rule/ground.html>

² <https://brave-rugby.com/rule/ground.html>

であるため、地面から **3m** 以上で **5.6m** の間をキックによって通せばゴール成功となる。ポールの高さはゴールを判定する審判が判定しやすいように **3.4m** 以上とされている。

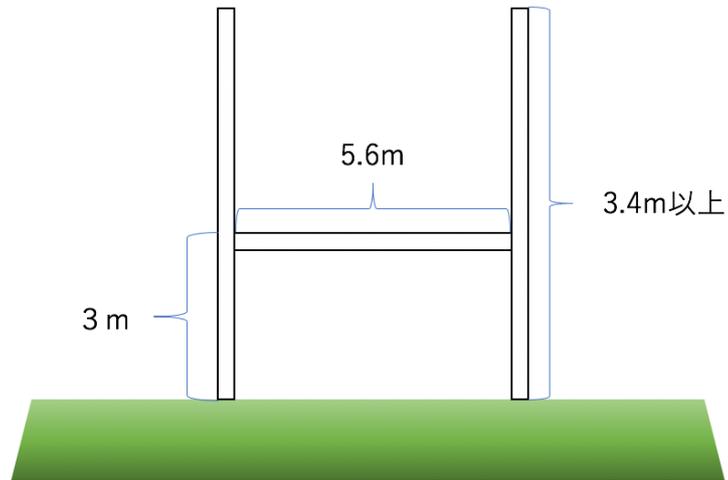


図 8 ゴールポスト

第3章 ゴール予測モデル

本章では、ラグビーのゴールキック予測モデルの構築について説明する。近年、日本ではラグビーワールドカップでの日本代表の活躍したことにより、メディアによって報道されるようになり、認知度が少し上昇していることは事実である。しかし、これまではラグビーがマイナースポーツであることや、競技人口が少ないことから、ラグビーポストがある小学校や中学校は少ない。そこで、私はポールがない場所でもゴールキックの練習をできるようにこのゴールキック予測モデルを構築したいと考えた。以下では、ラグビーのゴールキックの説明から、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 姿勢データの収集

ゴールキック予測モデルを構築するにあたり、ゴールキックの学習データとして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ラグビー部の選手 M 君に 50 回のゴールキックを行ってもらい、50 件のキック動画を取得した。50 回のキックは 22m ライン上で、ゴールポストに対して右左斜め 50 度 13 本ずつ、正面 8 本、右左斜め 40 度 8 本ずつで代表的な 5 種類の位置で計 50 本行った。そして、ゴールの可否を記録した。50 件の結果をまとめた表が表 2 である。グラフの 1~8 回目が正面、9~16 回目が右斜め 40 度、17~29 回目が右斜め 50 度、30~37 回目が左斜め 40 度、38~50 回目が左斜め 50 度である。ゴール成功を○と示し、不成功を✕と示した。

表 2 50 回のゴールキック

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
✕	✕	✕	✕	✕	○	✕	○	✕	✕

3.1.1 動画から姿勢データの抽出

上記で記述した 50 件のキックデータをゴールキック予測モデルの学習で利用できる姿勢データにする必要がある。まずは 50 件のキックデータから Openpose を用いて、25 点の関節データを抽出し、50 件の json データを生成した。しかし、その json データには関節情報以外の学習で必要のない値が含まれているため、json データから 25 点の関節の XY 座標だけを抽出しなければならない。また、学習に用いるために一つの姿勢データ（図 9 参照）にするため 50 件の関節データの統合を行った。動画にはフレーム数という画像のコマ数の様なものがある。50 件の動画はそれぞれフレーム数が 100 になるように揃えた。そして、それぞれの関節点の数 25 個が XY の座標により $25 \times 2 = 50$ 、そして、位置データがキックの場所（今回の実験では 5 箇所を 0~4）とするため 51 次元の $50 \times 100 \times 51$ の三次元配列のデータを生成した。これは配列の計算を行うためのモジュール Numpy を使い、ndarray 型の配列である。

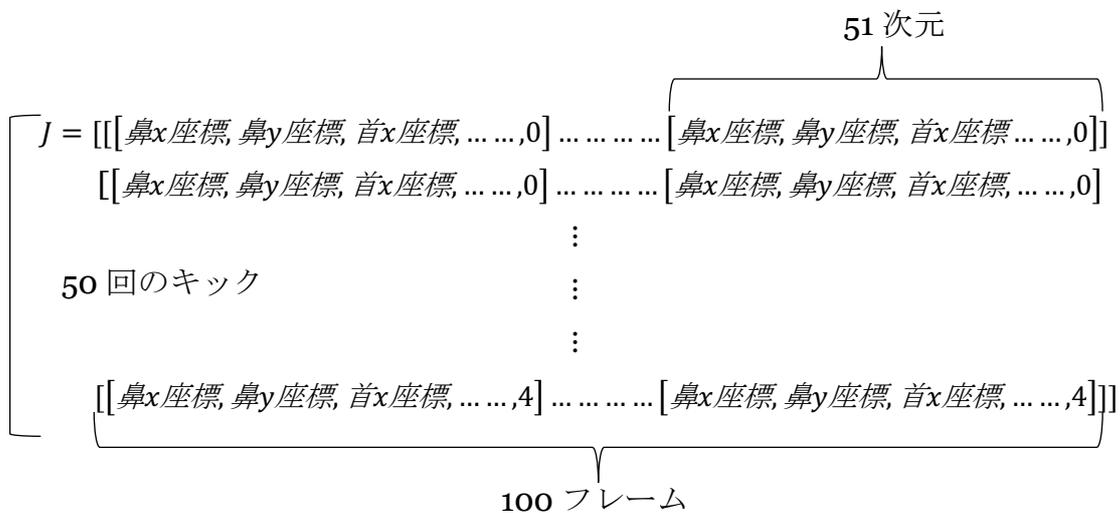


図 9 生成した姿勢データ

3.1.2 データの拡充

第1章でも述べたようにゴール予測モデルを構築するには、大量かつ多様なゴールキックの姿勢データが必要である。特に、ラグビーのゴールキックはトライした場所によって、ゴールキックを行う場所が変わるため、蹴る位置の異なるデータが必要となり、大量のデータを収集することが困難である。ラグビーのゴールキッカーはコンタクトプレーなどの練習を他の選手と同様にするため、体の疲労からも、ゴールキックを多くの本数行うことは難しい。その中で大量のキックデータを収集するために考えたのが姿勢データの拡充である。Openposeを基に読み込んだデータにおける関節の座標からランダム距離分だけ平行移動させることで疑似的にデータ数を拡充する事が出来た。これを利用して、100, 500, 1000, 2000, 4000 件のそれぞれの件数にデータを拡充し、学習した。

3.2 LSTM によるモデル構築

本研究では、ゴールキック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層の一つである LSTM を用いた。この LSTM とは、「Long Short Term Memory」を略した言葉で、ディープラーニングが流行する前から存在しており、1997 年に原著論文が発表された。まず、ディープラーニングとは人間が脳などを使って自然に行うことをコンピュータに学習させる機械学習の一つである。ニューラルネットワークがベースになっており、多層にすることでデータに含まれる特徴をより学習できるようになる。そして、このディープラーニングの中で有名である技術が RNN であり、その中の LSTM が予測モデルで使われる事が多い。この RNN や LSTM は多くの時系列データを入力し、何度も RNN や LSTM に学習させる事でその時系列データに対する結果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 は時系列が長くなると重みがかかる回数が多くなるため、勾配消失問題が発生し、長期依存を学習できないが、LSTM は時系列を考慮する事ができるため、このような問題を解消できる[3]。LSTM は様々な分野で活用されており、様々な予測モデルがある。例えば、犯罪認知件数から時間や場所を抽出し、それを入力データとし予測モデルを構築する事で、近くで犯罪が起こりやすいことや、犯罪が起こる時間を予測するというような研究がある[4]。その他にも誤字脱字を予測するような言語に関する予測モデル[5]や、ダム貯水池の流入量[6]を予測し、ダムに急激な水位上昇を起こさないための環境に関する予測モデルの研究も行

われている。

本研究のゴールキック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場所である位置データを入力データとし、ゴールの成功不成功を教師信号として学習を行った。

3.2.1 RNN

上記でも述べた RNN について詳しく説明する。RNN とは Recurrent Neural Network (リカレントニューラルネットワーク) の略であり、日本では「回帰型ニューラルネットワーク」などとも呼ばれている。RNN は過去の情報を記憶することで、その情報から新しい事柄を処理できる。RNN は主に、自然言語処理の分野で使われている事が多い。例として、言語モデルと文章生成がある。言語モデルは直前の言葉から、文章の中における次の言葉の出現確率を予測する事ができるのである。では、RNN の構造について図 10 を用いて説明する。RNN は 3 層からなっており、入力層、1 層の中間層、出力層である。入力層とは図 11 では J_t であり、学習に用いるものを入力する層である。そして中間層は図 11 で A の部分であり、再帰的に出現するネットワーク構造でセルと呼ばれる。中間層では入力された情報を演算し、演算結果を出力層に出力すると同時に再び入力として中間層に代入するという事を繰り返すことによって再演算していく。出力層は図 11 で h_t で表している。出力層では中間層で演算した結果を出力として出すが、ある層の出力は次の層の入力として用いられる事もある。RNN の特徴として、ある時刻での入力がそれ以降の出力に対しても影響するのである。つまり、過去の入力情報を基に予測する事ができるのである

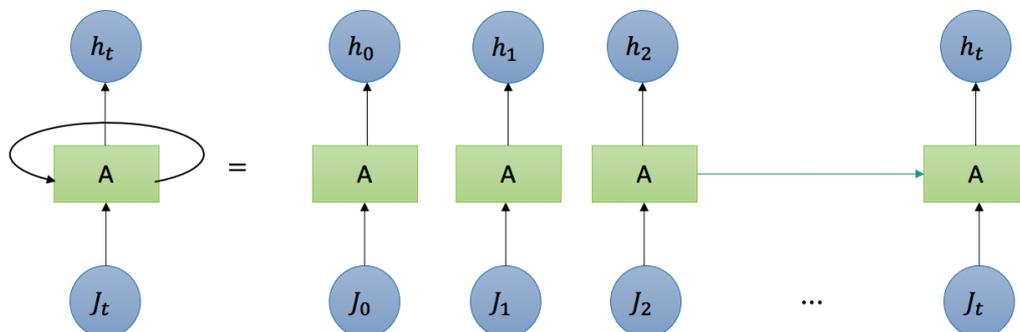


図 10 RNN の構造

3.2.2 LSTM ネットワーク

LSTM は RNN の勾配消失問題を解決したことで、長期依存の事象を学習できるようなモデルである。LSTM ネットワークの構造は通常の再帰型ネットワークと同じ構造を持つ。しかし、LSTM は RNN の中間層を LSTM Block という変換ユニットに置き換えることで、長期依存することができる学習をする事ができる。LSTM ネットワークの構造を図 11 で示した。まず、LSTM Block はセル状態とそのセル状態を保護、制御するためのゲートが 3 つある[4]。セル状態は図 11 の LSTM Block の中の上部を通っている水平線で示している。LSTM は、セル状態に対して情報の追加や削除する機能を持っており、この操作が 3 つのゲートと呼ばれる構造によって制御される。LSTM では最初のステップとして、①の忘却ゲート (Forget gate) と呼ばれるシグモイド層によって、セル状態から捨てる情報を判定する。時刻 $t-1$ の隠れ層出力の h_{t-1} と時刻 t の入力である X_t を見て、古いセル状態である C_{t-1} の各数値のために、その結果を σ で表しているシグモイド関数によって入ってきた情報を維持するか、取り除くかを処理する。次のステップとして、②の入力ゲート (Input gate) と呼ばれるシグモイド層によって、どの値を更新するかを判定する。そして、 h_{t-1} と X_t の情報を $\tan h$ 層で変換し、新たな候補値としてベクトル C_t を作成し、セル状態に追加する。その後、最初のステップでも説明したようにベクトル C_t で取り除くと判定した値を取り除き、古いセル状態 C_{t-1} から新しいセル状態 C_t に更新する。最後のステップとして③の出力ゲート (Output gate) にて出力するものを判定する。出力ゲートでも、これまでのゲートと同じようにシグモイド層によって処理し、セル状態のどの部分を出力するかを判定し、その結果だけを出力するために $\tan h$ を掛けて必要な情報のみを出力する。ここまでの LSTM ネットワークの基本的な構造であり、モデルによって、LSTM の構造が変わることもある。LSTM おバリエーションの中でも有名な一つが「のぞき穴の結合」というものである。これは 3 つのゲート層それぞれでセル状態を見させるようにするものである。

この図 11 で説明したように LSTM では 3 つのゲートによってデータが変換される。シグモイド層では情報を判別するとき制御する働きをし、 $\tan h$ 関数は RNN での問題である勾配消失問題を起こさないような働きをしている。

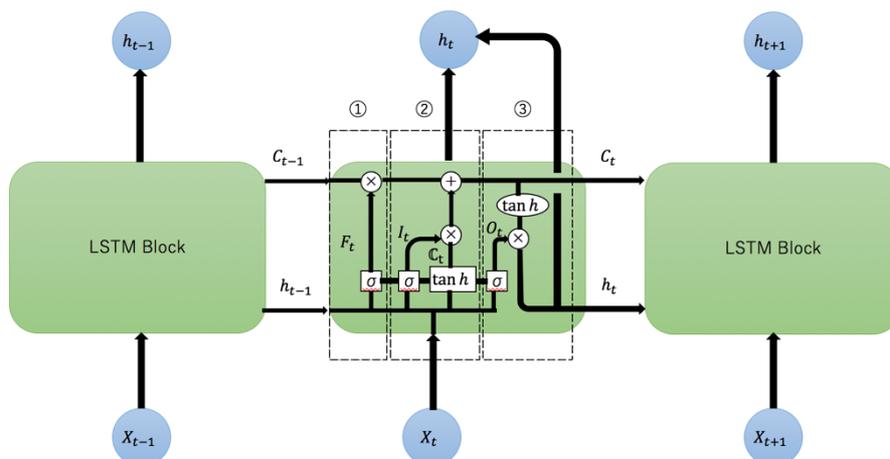


図 11 LSTM 構造

3.3 全姿勢データを用いたモデルの予測精度

本研究では 3.1.2 でも述べたように 50 件のデータから 100, 500, 1000, 2000, 4000 件にデータ拡充し、それぞれの全姿勢データを用いたモデルの精度を検証した. 表 3 ではそれぞれに拡充した精度をまとめた. 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がランダムに割り当てられるため、精度が毎回同じになるとは限らない. そのため、複数回プログラムを実行し、複数回の精度の平均を出した. そして、図 12 では横軸をデータ数、縦軸を精度とするグラフを作成し、比較を行った. 本研究の予測モデルを構築する際の課題として、大量のデータの収集が困難という事があった. 学習のために大量のキックデータを集めることが必要であった. この表 3 から分かるように、50 個のデータだと学習データが少ない事から精度が 48%と、50%を下回る低い精度となった. しかし、データの拡充によって、図 12 を見れば分かるように右肩上がりに精度が上がっている. 50 個と 4000 個を比べると、精度が 26%上がっており、データ数が学習にとって重要であることが分かる.

表 3 全関節を用いた各データ数の精度

	50	100	500	1000	2000	4000
精度	48%	52%	58%	66%	66%	74%

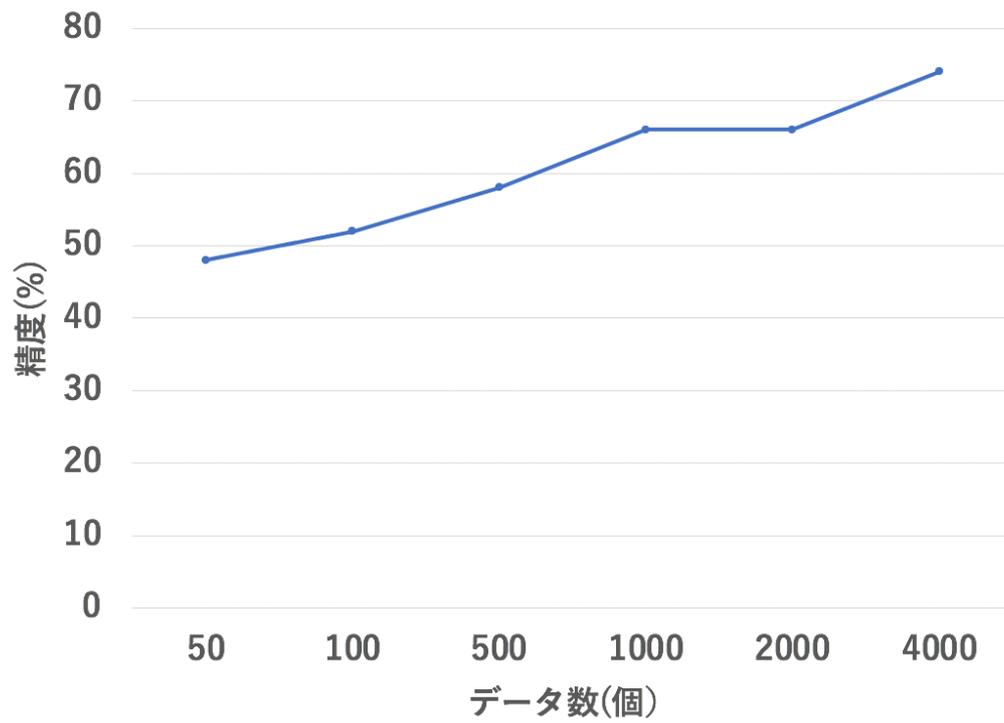


図 12 データ拡充による精度の変動

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、日本でラグビーワールドカップが開催されたことで、ラグビーの強化が加速している。近年ではプレーの向上のためにラグビーにおいて IT 技術を活用するチームがほとんどである。ラグビーの中でも有名であるスクラムではドローンなどのカメラを活用し、分析を行っている。また、Sportscode という編集ツールを使い、映像の中からそれぞれのプレーをクリップし、「タックル」、「キック」、「反則」などの名前をつけ、分析をやすくすることで、パフォーマンスの向上を図っている。しかし、ゴールキックに関してはチームで分析しているチームは全国の中でも非常に少ない。なぜなら選手はそれぞれキックのフォームが異なるからである。そのため、ゴールキックはプロ選手としてゴールキッカーを担ってきた選手の経験を生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ゴールキックにおけるドメイン知識に基づいた accuracy を出した。

4.1 ドメイン知識

ドメイン知識とはある専門分野に特化したその分野の知識であり、解析しようとしている業界や事業についての知見のことを言う。本節ではラグビーのゴールキックにおけるドメイン知識について現状の指導内容や選手の意見を紹介しながら説明する。

4.1.1 指導内容

ここでは本研究で用いたゴールキック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。この指導内容は元ラグビー日本代表の大西将太郎からお聞きしたものである。大西は現役時代ゴールキッカーを務めており、2007年に行われたラグビーワールドカップではカナダ戦の試合終了間際に決めた同点のコンバージョンキックはラグビー界では誰もが知るゴールキックである。現在、大西はラグビーのテレビ放送の試合解説や、テレビ番組などにも出演されておりラグビー界のレジェンドである。では図 13 の指導内容についてそれぞれ説明する。1 番目、「足がボールに当たるまでの一貫性」はキッカーがキックするまでの準備から足のスイングまでを一つの行動のように毎回同じようにこなす事である。キックするまでの準備には助走の距離、角度や助走のスピードリズムがあり、時によって異なってしまうとフォームが変わってしま

ゴールキック指導内容

1. 足がボールに当たるまでの一貫性
2. 自分の胸がボールに近づくイメージ
→体が開かない
3. ボールを最後まで見る（蹴った後まで）

図 13 大西の指導内容

う。そして、足のスイングはボールを飛ばす方向に非常に関係しているため、足のスイングまでを一連の流れとして身につけることが大切である。足のスイングを意識するためには、蹴る方の足首と膝の関節が重要であると考えられる。2番目、「自分の胸がボールに近づくイメージ」はボールを蹴る瞬間の姿勢のことである。ボールを蹴る時にこのようなイメージを持つことで、体が開かないことにつながる。体が開いてしまうと体の重心がぶれてしまうためボールに力が伝わりにくい事や体のブレがボールのブレにつながることもある。この事から **Openpose** で取得可能に胸はないため、同じ軸上にある両肩の関節が重要であるのではないかと考える。最後の 3 番目「ボールを最後まで見る」はボールの蹴る部分に上手く足の甲を当ててるためである。最後までボールを見ていなければ、上手くボールに足の甲を当てられず、狙った所にボールを飛ばせずゴールを外してしまう可能性が高くなる。また、ボールを見ると言う行為は2番目の「自分の胸がボールに近づくイメージ」にもつながるため、姿勢という面においても重要であると考えられる。実際にゴール成功した時の姿勢画像が図 14, 15 である。図 14 が蹴る瞬間、矢印の方向のボールを見ている画像で、図 15 では蹴った後であるが同様にしっかりとボールを見ているのがわかる。これらの指動内容から蹴る方の膝と足首、両肩、両目の関節が重要である事が分かった。



図 14 蹴る前



図 15 蹴った後

4.1.2 選手に対するアンケート

ゴールキック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「ゴールキックの時に意識している関節を3つあげるとするとどこの関節か?」というアンケートを取った。アンケートの結果は表4, その結果を集計したものを図16で示している。このアンケートの対象である全員の選手が蹴る足の膝は重要だと答えた。また, 10人中8人の選手が蹴る足の足首が重要であると答えたため, 大西さんによる指導内容と共通する関節であるので, ゴールキックにおけるドメイン知識の関節だと言える。図16を見れば分かるように, 軸足の足首も半数以上の選手が重要だと答え, 唯一上半身の関節である軸足の肩を重要だと考える選手も4人いた。指導内容では上半身の重要性が挙げられているが, 選手は上半身の関節を意識している選手が50%を満たさない事から, ゴールキックの指導にもさらに力を入れる必要がある。

表4 10人の現役のゴールキッカーが意識する3つの関節

	関節1	関節2	関節3
選手A	蹴る足の膝	蹴る足の足首	軸足の肩
選手B	蹴る足の膝	蹴る足の足首	軸足の足首
選手C	蹴る足の膝	蹴る足の足首	軸足の足首
選手D	蹴る足の膝	腰	軸足の肩
選手E	蹴る足の膝	蹴る足の足首	軸足の足首
選手F	蹴る足の膝	蹴る足の足首	軸足の肩
選手G	蹴る足の膝	軸足の足首	軸足の肩
選手H	蹴る足の膝	蹴る足の足首	腰
選手I	蹴る足の膝	蹴る足の足首	軸足の足首
選手J	蹴る足の膝	蹴る足の足首	軸足の足首

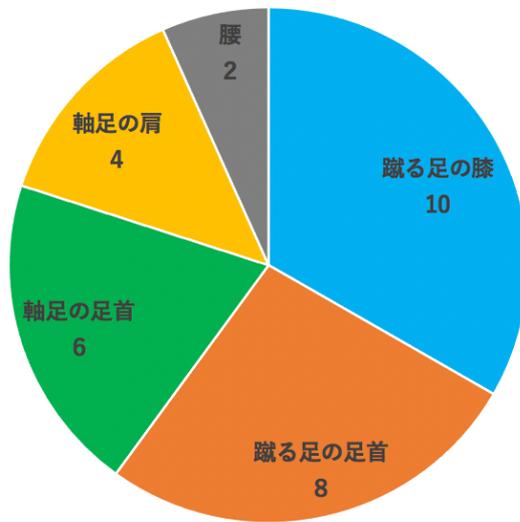


図 16 ゴールキッカー10 人に対するアンケートの集計結果

4.2 ドメイン知識を用いたモデルの予測精度

前節で紹介したゴールキックにおける指導内容や調査したアンケート結果から、共通して重要だとされる関節がある事やラグビー界でトップクラスの指導者である大西さんの指導内容を中心としドメイン知識として用いる関節を抽出した。また、このゴール予測モデルを用いてゴールキックの指導をする時に意識させる関節が多過ぎると難しいため、ドメイン知識として抽出する関節をできる限り少なくした。今回ゴールキック予測モデルで用いたキックデータに協力してもらった M 君は右利きのキッカーであるため、蹴る足を右とする。ドメイン知識として用いた関節が 2 の RShoulder のデータ, 5 の LShoulder, 10 の RKnee のデータ, 11 の RAnkle のデータ, 15 の REye のデータ, 16 の LEye のデータの 6 箇所である。そして、第 3 章と同様に、この 6 個の関節データを用いたデータを拡充し、それぞれのモデルの精度を検証し、図 17 で比較したグラフを示す。ドメイン知識を用いたモデルにおいても、全関節データの時と同様に 50 個のデータだと学習データが少ない事から精度が 46%と、50%を下回る低い精度となった。しかし、データの拡充によって、図 17 を見れば分かるように右肩上がりに精度が上がっている。50 個と 4000 個を比べると、精度が 26%上がっており、データ数が学習にとって重要であることが分かる。1000 個のデータより 2000 個のデータの方が精度が低くなっているが、精度を出力するプログラムを複数

回実行し、それらの精度の平均を出したためこのような結果にもなり得る. 1000個と 2000 個のデータ数の差では精度があまり変わらないのである.

表 5 ドメイン知識における各データ数の精度

	50	100	500	1000	2000	4000
精度	46%	48%	56%	62%	60%	72%

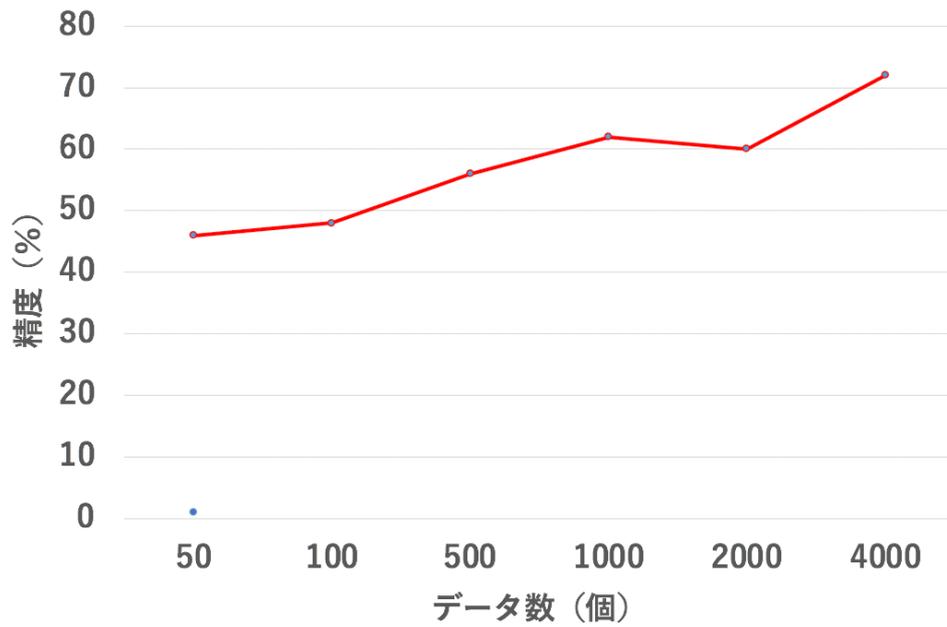


図 17 ドメイン知識におけるデータの拡充による精度の変動

第5章 考察

第3章で全姿勢データから LSTM を用いて予測モデルの精度を 50, 100, 500, 1000, 2000, 4000 件のそれぞれのデータ数で精度を比較した。同様に、大西さんの指導内容や選手に対するアンケートを基にゴールキックにおけるドメイン知識を選び、ドメイン知識の関節の座標を入力として学習し、その予測モデルの精度を比較した。そして、それぞれの比較した精度同士を比較する事で、ラグビー界でのゴールキックにおけるドメイン知識の有用性を検証した。有用性を示すために図 18 でそれぞれの精度比較グラフを重ね合わせ、考察を述べる。青い折れ線グラフが全関節の座標を用いた精度比較で、赤い折れ線グラフがドメイン知識の関節を用いた精度比較である。各データ数における精度を比較すると、どのデータ数を取っても全関節データの精度が高いが、しかし、それ程大幅に精度が落ちていない事が分かる。この結果から、ドメイン知識として用いた 2 の RShoulder のデータ, 5 の LShoulder, 10 の RKnee のデータ, 11 の RAnkle のデータ, 15 の REye のデータ, 16 の LEye のデータの 6 箇所はゴールキックの成否に重要な関節であることが検証された。しかし、どちらも 50 件のデータの精度が 50%を下回っているため、オリジナルデータとして使うキックデータ件数が少ないと言える。

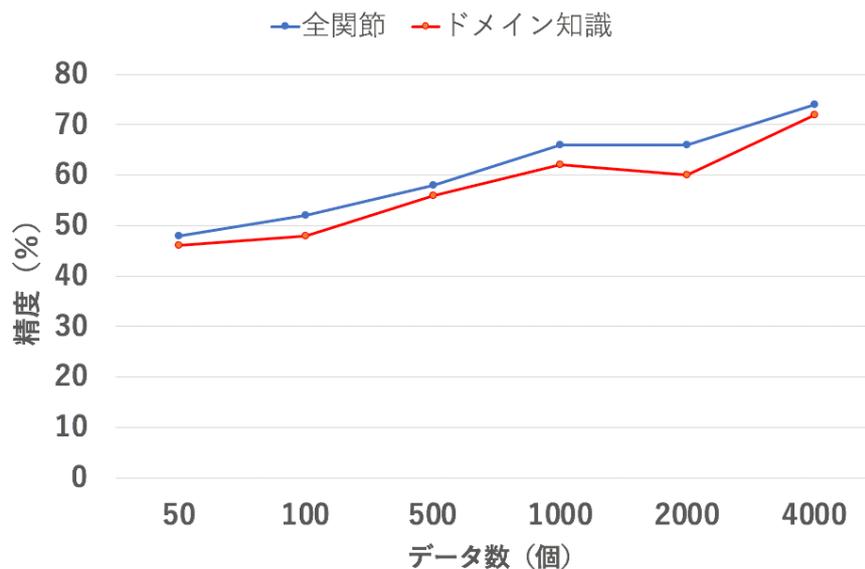


図 18 全関節データとドメイン知識におけるデータの精度比較

また、両サイドの5 m から蹴った動画の精度が低く、キックの動画を確認するとゴールポストに対して角度がある時には力んでしまい、フォームが崩れていたのが原因である。

第6章 おわりに

本研究では Openpose を用いて、キックデータから関節データを抽出し、LSTM で学習をする事でラグビーのゴールキック予測モデルを構築した。代表的なゴールキック位置を5箇所選択し、50件の姿勢データを収集した。しかし、50件のデータ数ではLSTMで学習するために少なかった。なぜなら、50件で構築した予測モデルの精度が50%を下回っていたからである。そこで姿勢データの関節の座標を並行移動して、100, 500, 1000, 2000, 4000件に学習データを拡充することで、50件から4000件にデータを拡充すると約26%程度 Accuracy を向上させることができた。オリジナルのキックデータ件数を増やす事で、さらに精度を上げることができ、より精密な予測モデルを構築できる。この予測モデルはゴールポストがない環境で練習している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。

二つ目の研究目的であるゴールキックの指導で意識させている関節が本当に有用な関節であるかどうかを検証するために、ドメイン知識に基づいて選択した関節を対象とした姿勢データと、全関節を対象とした姿勢データを用いてゴール予測モデルを構築し、それぞれの精度比較を行った。実験の結果からドメイン知識に基づくモデルが全関節データを用いたモデルと同程度の精度であったことから、ドメイン知識である、両目、両肩、蹴る足の右膝、蹴る足の右足首の位置がゴールキックの成功の可否に重要な要因であることが検証された。よって、現在のラグビー界での指導内容は正しいということが考えられる。

本研究では風や天候を予測モデルで条件として入れていないことや、誰もいない状況を前提に構築したため、足がボールに当たるポイントのずれや軸足のずれは考慮していない。しかし、実際の試合ではそのようなことが原因でゴールが外れることもあるため、それらの条件も含めたゴールキック予測モデルを構築できれば、より実用的なモデルになると考えられる。また、予測モデルに用いる関節を様々な組み合わせで検証することで、ラグビー界では知られていない重要な関節が見つかるかもしれない。

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] 金子和樹, 中村拓馬, 矢入郁子, 平田均: Openposeを用いたサッカー熟練度の分類, 人工知能学会全国大会論文集, 2020年JSAI2020 巻 3M5GS1205 (2020)
- [2] 高崎智香子, 竹房あつ子, 中田秀基, 小口正人: 姿勢推定ライブラリOpenposeを用いた機械学習による動作識別手法の比較, 第81回全国大会講演論文集, 2019巻, 1号, p275–276(2019).
- [3] 本多誠之, 辰巳賢一, 中川正樹: LSTMによる光環境変動下におけるイネ個葉の光合成速度の予測, 農業情報研究, 30巻, 2号, p96–108 (2021)
- [4] 張曉齊, 米澤剛, 吉田大介: オープンデータとLSTMを用いた犯罪発生の予測及び時間的近接性における考察, 情報学, 16巻, 1号, p56–70 (2019)
- [5] 高橋諒, 蓑田和麻, 舛田明寛, 石川信行: Bidirectional LSTMを用いた誤字脱字検出システム, 2019年度人工知能学会全国大会, 2019年JSAI2020 巻 3C4J903 (2019)
- [6] 天方匡純, 梁田信河, 藤井純一郎: LSTM(Long Short-Term Memory)を活用したダム流入量予測に関する研究, 電力土木技術協会, 405号, p11–18 (2020)