

# 釣り上達支援システムの実現に向けた キャスト種類の分類および評価

近藤 亮介<sup>1,a)</sup> 真弓 大輝<sup>1</sup> 松田 裕貴<sup>1</sup> 諏訪 博彦<sup>1</sup> 安本 慶一<sup>1</sup>

**概要：**釣りは人気のレジャースポーツであり、その技術は釣果に大きく影響を与える。しかし、釣りの技術はユーザーの経験に左右され、評価が難しいという課題がある。そこで、釣りの技術を定量的に評価することで、技術のマニュアル化やユーザーに合わせたアドバイスが可能になると考えられる。本研究では、釣竿を振って仕掛けを飛ばすキャスト動作に着目し、リールと呼ばれる釣具に装着したセンサから得られるデータを利用して、キャストの分類モデルの構築および評価を行った。被験者 6 名からキャスト動作のデータを収集してデータセットを作成し、LightGBM を用いて分類モデルを構築した。分類モデルの評価のため、Leave-One-Session-Out 交差検証および Leave-One-Person-Out 交差検証を利用した。検証の結果、Leave-One-Session-Out 交差検証において正解率 98.1%、F 値 98.1% の精度を、Leave-One-Person-Out 交差検証においては正解率 86.9%、F 値 87.3% の精度を確認した。また、ユーザーが予め自身のキャスト動作のデータを登録した上で、分類モデルを学習および運用することを想定し、Leave-One-Person-Out 交差検証において検証用となるユーザーのデータの一部を学習用データに追加して、分類モデルを一から学習して検証を行った。その結果、最大で正解率 96.1%、F 値 96.1% の精度を確認した。

**キーワード：**釣り、センシング、行動認識

## 1. はじめに

釣りは古くから親しまれてきたアウトドアレジャーであり、多くの愛好者がいる。釣りはコロナ禍においても外で密集しない状況で行う特徴も合わさり、レジャー白書 2021 によると 2021 年には約 560 万人を記録しており、ゴルフ・登山・スキー・スノーボード・キャンプといったアウトドアレジャーを抑えて 2 年連続 1 位を記録している [1]。より良い釣り体験を釣りユーザーに提供するため、釣具も時代と共に進化してきており、特に近年では、ICT を活用した釣具も登場している。例えば、株式会社スマートルアーが開発した smartLure Model Zero[2] では、ルアーの中にセンサが組み込まれており、着水から離水までの間の水中の温度や明るさ、ルアーの動き、水深をトレースする機能を有している。また、株式会社 Baltic Vision が販売する Deeper スマートソナー [3] は、釣糸の先端に取り付けて投げられるポータブル魚群探知機であり、スマートフォンなどのモバイル端末のアプリと接続することで、ソナーモニターやマッピングといった機能を活用することができる。

しかし、ICT を用いた釣具によって釣りユーザーの釣り体験は多様化してきている一方で、釣りにおける技術向上を支援する釣具やシステムは存在していない。釣りの動作の記録はスマートフォンに手動で入力するなど自動化されておらず、釣り技術の向上のためには、釣り人の動作そのものを自動で記録・判別し、その動作内容に関する質を評価する必要がある。

そこで、本研究では釣りの動作を客観的に評価し、そのデータを活用した効果的なフィードバックを行うシステムを開発することを目的とする。具体的には、釣りの動作を数値化しデータ蓄積を容易にする仕組みを構築し、同時に釣りにおける特定の動作を自動的に分類する手法を提案する。これにより、収集されたデータを元に評価を行い、適切なフィードバックを提供することで、釣り技術の効率的な向上を図る。

本稿では、システムの実現に向け、釣りにおける基本的な動作であるキャストに着目し、3 種類のキャスト（オーバーヘッドキャスト・サイドキャスト・ピッチング）を機械学習を用いて分類するモデルを構築した。分類モデルについて、複数のシステム利用場面を想定して検証を行った結果について報告する。

<sup>1</sup> 奈良先端科学技術大学院大学,  
Nara Institute of Science and Technology

<sup>a)</sup> kondo.ryosuke.kn7@is.naist.jp

## 2. 関連研究

### 2.1 釣りセンシング

不破らは、ルアー釣りにおける釣り動作と釣糸張力の解析を、ひずみゲージとカメラによる画像解析を用いて行っている [4]。釣糸張力は上・中級者が初心者より大きい値を示し、また上級者には約 0.5 秒の卓越周期が顕在していることを確認している。また、動作解析について、上級者は安定した姿勢で手首を細かく動かしていることを確認している。

福田らは、釣果情報共有を目的とした釣竿の振動データに基づく魚種分類手法や釣り人の行動認識について取り組んでいる [5], [6]。文献 [5] では、防波堤 3 か所で釣り上げた 28 匹の魚の振動データに対して、周波数解析およびバンドパスフィルタとピーク検出による魚種分類を行っている。その結果、ピーク点ごとの間隔に着目した特徴量を主成分分析で可視化することで、9 つの魚種のうち尾数の多かった 5 つの魚種についてグループ分けができることを示した。文献 [6] では、釣竿に取り付けた IMU を用い、釣り人の 5 種類の行動（投げる、リールを巻く、移動する、エサをつける、待つ）を認識する機械学習モデルの構築と評価を行っている。その結果、F 値が 0.784 の精度で行動が認識できることを確認している。また、福田らは釣果が無い時における意思決定支援のための釣り CPS (Cyber Physical System) を提案している [7]。CPS とは、IoT で得られるフィジカル空間の情報とサイバー空間に蓄積された膨大な情報を AI が解析し、その解析結果をフィジカル空間の人間に様々な形でフィードバックするシステムである。このシステムは、GPS と慣性センサを用いて釣り人の行動をリアルタイムで認識し、時間および場所に応じた釣果に結び付く過去の有用な行動に関する情報を提供する。

難波らは、ルアーキャストにおける動力学モデルを構築し、釣竿や釣糸の初期角度がルアーの飛距離に与える影響を解析している。その結果、釣竿の初期角度を大きくとることで飛距離を得やすくなり、また釣竿の初期角度が比較的大きい場合は釣糸の初期角度も大きくとる必要があることを確認している [8]。

### 2.2 他のスポーツにおけるセンシングデータ解析

Blank らは、卓球の上達支援システムの開発を目的として、卓球ラケットに取り付けた慣性計測装置 (IMU: Inertial Measurement Unit) を用いて、アマチュア選手とプロ選手 10 名のストローク動作の検出とその種類の分類を行った [9]。ストローク動作の検出は、Blank らの独自アルゴリズムにより、サンプリング周波数 1000Hz で取得された時系列データから抽出される。それらのデータに対して、基本的な 8 種類のストロークの種類を正解デー

タとしてラベリングを行い、機械学習の解析ソフトである ECST と WEKA を用いて、Naive Bayes, Random Forest, Support Vector Machine (SVM) など、6 つの分類アルゴリズムにより、行動認識モデルの構築を行った。その結果、Radial Based Function Kernel を用いた SVM モデルにより、Accuracy 96.7 % の精度で、行動を認識できることを報告している。

鳥越らは、剣道競技における IMU を用いた打突動作の検出と認識手法を提案している [10]。剣道経験者 7 人と未経験者 7 人からなる 14 人の被験者を対象に、右手首、腰、竹刀鏝、竹刀先革に取り付けられた IMU 搭載のセンサ SenStick [11] を用いて、サンプリング周波数 100Hz で加速度および角加速度データを収集した。それらのデータをもとに、まず、加速度の時系列データからの DTW 距離 [12] に基づいて打突動作を検出している。検出対象である打突動作は、中央面、右面、左面、胴、小手の 5 種類である。同一被験者の学習データを使用すると、F 値 89.9 % の精度で打突動作が検出できることを確認している。同様に、剣道経験者の学習データを使用することで、95.0 % の精度で打突活動が検出できることを確認している。その後、5 種類の打突動作および 3 種類の打突動作（面、胴、小手）の認識を行っている。Person-Dependent の場合、右手首のセンサデータのみで 89.5 % の精度を達成している。また、右手首と竹刀鏝のセンサデータを組み合わせることで 91.8 % の精度を達成しており、複数の位置のセンサデータを組み合わせることで分類精度がさらに向上することを明らかにしている。一方で Person-Independent の場合、右手首、竹刀鏝、竹刀先革の 3 つのセンサデータを用いて、5 種類の打突動作では 54.9 %、3 種類の打突動作では 69.3 % の認識精度を達成している。

また、鳥越らは、剣道競技者が単独でも効果的な練習を可能とする剣道上達支援システムの実現に向けて、ウェアラブルセンサによる打突動作の熟練度評価を行っている [13]。剣道競技者の身体と竹刀に IMU センサを装着し、センサデータを解析することで打突のフォーム・速さ・一貫性について評価している。

## 3. 提案システム

### 3.1 システム概要および構成

釣りにおいて魚を釣る際、最も基本的な動作は釣竿を振って仕掛けを飛ばすキャストである。キャストの正確さと適切な技術は、釣果に大きく影響を与える。適切なキャスト技術を駆使することで、釣りの対象エリアに餌やルアーといった仕掛けを正確に投げ込むことが可能となり、遠くのポイントにもアクセスすることが可能になる。これにより、魚の存在する場所に効果的に仕掛けを届け、釣果を向上させることが期待され、釣りの楽しさと満足感に繋がる。釣りの初心者はまずキャストの練習から始め、狙っ

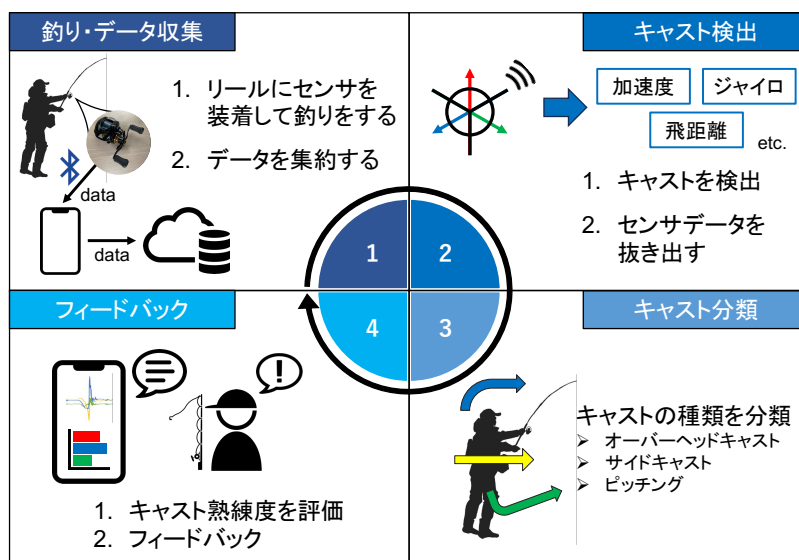


図 1: 提案システムの構成

た位置に仕掛けを飛ばせるようになることで、釣りの成果を向上させ、より充実した釣り体験に結びつくことが考えられる。

しかし、釣りの技術はユーザの経験に左右され、評価が難しいという課題が存在する。初心者の場合には、具体的にどの技術や要素が不足しているかを把握しにくく、上達に時間がかかることがある。周りに熟練者がいる環境で客観的な指導を受けることが望ましいが、熟練者の指導においても、アドバイスが主観的であったり、初心者のスキルや状況に合わせた指導が不足するといった問題が生じ得る。本研究では、センサを装着して IoT 化した釣具を用いた釣り上達支援システムの実現を最終目標とする。このシステムを通じて、ユーザが客観的フィードバックにより釣りの技術を向上させる環境を提供することを目指す。図 1 に提案するシステムの構成図を示す。提案システムは、(1) データ収集部、(2) キャスト検出部、(3) キャスト分類部、(4) フィードバック部の 4 部から構成される。

本稿では、データ収集・キャスト検出・キャスト分類までを行ったため、以下ではこれらの内容について報告する。

### 3.2 対象とする釣りの動作：キャスト

図 2 に、本研究において分析対象とする 3 種類のキャストの様子を示す。赤線で強調されているのは釣竿である。

#### オーバーヘッドキャスト

一般的で基本的なキャストの形である。釣竿を頭上に振り上げ、釣糸を振り子のように振り出して仕掛けを投げる。

#### サイドキャスト

釣竿を横に倒し、横方向に糸を振り出すキャストの形である。狭いスペースや特定の状況で使われ、障害物に近い場所への投げ込みがしやすい特徴がある。

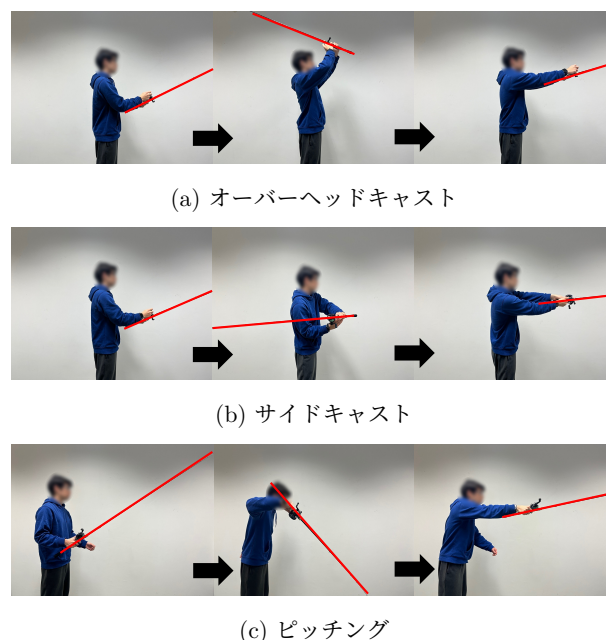


図 2: 釣りにおけるキャストの種類

#### ピッチング

アンダーハンドキャストとも言い、釣竿を体の下に傾けて仕掛けを手で持ち、低い位置から仕掛けを投げるキャストの形である。低い天井や密集した樹木の下など、制約がある状況で有用である。オーバーヘッドキャストやサイドキャストと比較して飛距離は短い。

### 3.3 リールの種類とキャスト検出

釣りにおける重要な釣具としてリールがあり、主要なリールの種類としてスピニングリールとベイトリールが存在する。図 3 にスピニングリールとベイトリールの例を示す。スピニングリールではベールアームを開くことで、ベ



(a) スピニングリール



(b) ベイトリール

図 3: リールの例

イトリールではクラッチレバーを押すことで、釣竿から釣り糸が出る状態になる。この状態の時に釣竿を振ることで仕掛けを飛ばすことが可能である。このように、釣りにはキャストを行う前に必ず行う行動が存在するため、この行動をセンサを用いて認識することでキャスト開始時の検出が可能になると考えられる。また、キャストによって仕掛けが飛んでいる間は釣り糸が引き出されており、ベイトリールではスプールが回転し続けることに相当する。そのため、スピールの回転数を検出することでキャスト距離の算出が可能になると考える。このように、センサを装着したリールを用いて釣り・キャストを行うことで、センサによりキャストが検出される。

### 3.4 キャスト分類

3.2 節で述べたように、本研究で分析対象とする釣りの動作はキャストであり、キャストには大きく分けてオーバーヘッドキャスト、サイドキャスト、ピッチングの 3 種類が存在する。キャストの種類ごとに用途および特徴が異なるため、キャストを分類した上で評価することが望ましい。また、分類が可能になると釣場ごとのキャストデータを収集することができ、釣場を利用するユーザがどの種類のキャストを用いることで釣果に繋がるかを確認することができるようになる。そのため、センサによって得られたデータをキャストの種類ごとに分類することが求められる。本研究では、機械学習を用いてキャストの分類を行う。機械学習に用いる特徴量作成のため、得られる時系列 3 軸加速度から合成加速度を導出する。同様に、得られる時系列 3 軸角速度をから合成角速度を導出する。また、3 軸および合成データから統計量として最大値・最小値・平均値・

分散を導出し、特徴量として用いる。IMU データの他には、スプールから釣り糸が出ている時間をキャスト時間とみなし、そこから得られる飛距離やキャスト時間を特徴量として用いる。

## 4. キャスト分類評価実験

### 4.1 実験目的と概要

本実験では、リールに装着されたセンサから得られるデータを用いて、釣りの基本動作であるキャストの種類を分類可能かどうかを実験を通じて確認することを目的とする。初心者および熟練者である被験者 6 名を対象に、ベイトリールを装着した釣竿を利用してキャスト動作を行ってもらい、キャストのデータを収集した。計 6 名から収集されたキャスト動作のデータセットを作成し、機械学習モデルを用いてキャスト分類モデルを作成した。その後、分類モデルの評価実験として Leave-One-Session-Out 交差検証および Leave-One-Person-Out 交差検証を行った。

### 4.2 データ収集

#### 4.2.1 使用するリール

センサの装着位置としては、釣りのキャスト動作に与える影響を最小限にする位置が望ましい。まず、センサを装着する道具として釣竿とリールが考えられるが、釣竿にセンサを装着するとセンサが釣り糸と干渉して仕掛けを適切に飛ばすことができず、ユーザの釣り体験を損なう可能性があるため、本研究ではリールに装着することを選択した。また、使用するリールの種類について、3.3 節で説明したスピニングリールとベイトリールが考えられる。スピニングリールでは、釣り糸をロックする役割を持つベールアームがフリー回転する機構となっており、加えて形状が細いためセンサを装着しにくい。一方で、ベイトリールにおいてロックの役割を持つのはクラッチレバーであり、クラッチのオンオフに際してレバーが固定される機構をしている。ベイトリールの方がスピニングリールに比べて実現可能性が高いと考えてベイトリールを選択した。

#### 4.2.2 キャストの手順と収集データ

図 4 にキャストを行う際の手順と取得するデータの関係を示す。ベイトリールを用いてキャストを行う際の手順は、1. 釣竿を構える、2. クラッチレバーを押し下げる、3. 釣竿を振りかぶる、4. 仕掛けを投げる、これら 4 つに大きく分けられる。ここで、クラッチレバーを押し下げた瞬間をクラッチ時刻、仕掛けを投げてスプールが回転し始めた瞬間をキャスト時刻とすると、クラッチ時刻からキャスト時刻までを precast 区間、キャスト時刻からスピールの回転が止まる時刻までを cast 区間とする。

取得するデータについて、本実験ではキャストを分類するにあたり、キャストのモーションデータとスピールの回転数データを取得した。モーションデータ取得のために

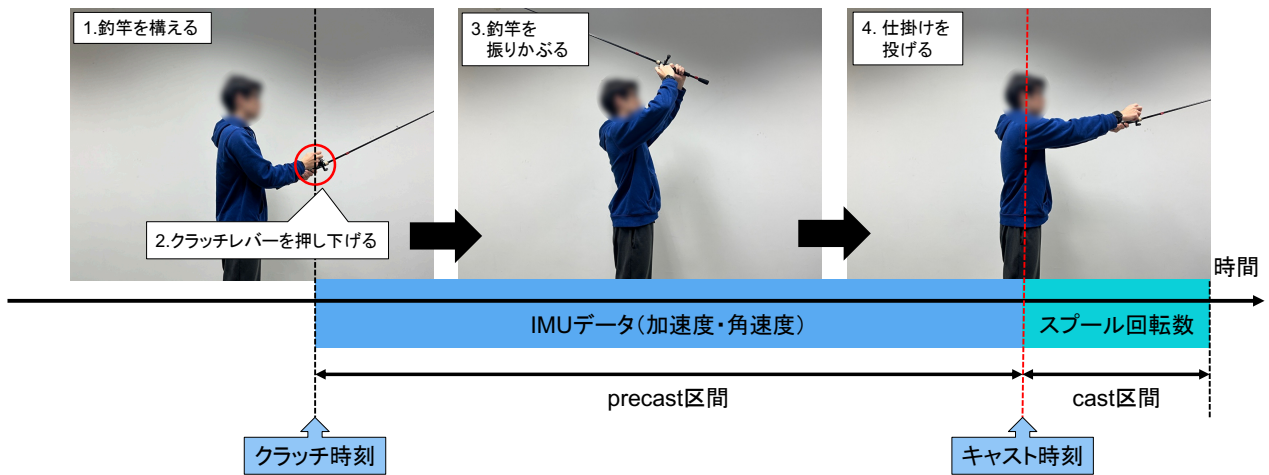


図 4: キャストを行う際の手順と取得するデータの関係

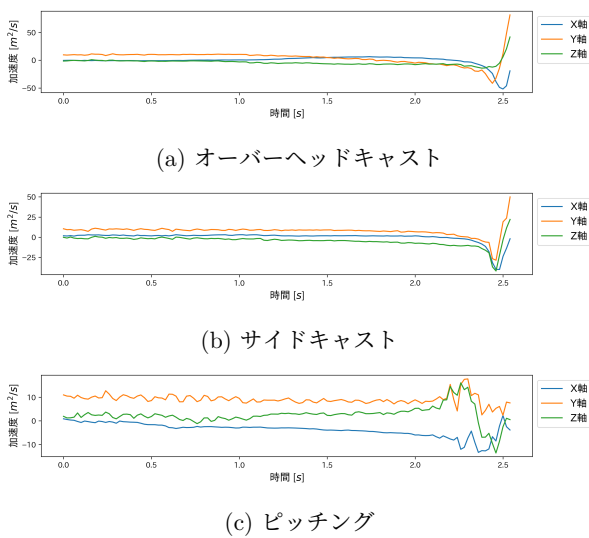


図 5: 記録される加速度データの例




図 6: 記録される角速度データの例

IMU センサを利用し、右ハンドルであるベイトリールの左側面に装着した。また、クラッチ時刻とキャスト時刻を検出するためにスプールとクラッチレバーにもセンサを装着した。収集した IMU データについては、precast 区間のものを利用する。また、スプール回転数は cast 区間でのみ検出される。図 5 および図 6 にリールに装着したセンサによって計測される加速度データと角速度データの一例を示す。

#### 4.2.3 データセット

表 1 に示すように、3 人の釣り経験者と 3 人の釣り初心者あるいは未経験者を含む、計 6 名の被験者からキャスト動作のセンサデータを収集した。ベイトリールを用いた釣りの初心者もしくは未経験者である C・D・E・F は、経験者 A・B による軽い指導を受けた後にキャスト動作の計測を行った。被験者には 3 種類のキャスト（オーバーヘッドキャスト、サイドキャスト、ピッチング）を 20 回ずつ

表 1: 実験参加者のデータ

実験参加者	年齢	性別	釣り経験年数
A	20 代	男	7
B	20 代	女	5
C	50 代	男	13 (いかに釣り)
D	40 代	男	0
E	30 代	男	0
F	20 代	男	0

行ってもらい、結果として合計 360 回のキャスト動作のセンサデータを収集した。

#### 4.3 キャスト分類モデルの作成

収集したキャストのデータセットを用いて、3 種類のキャスト（オーバーヘッドキャスト、サイドキャスト、ピッチング）の分類モデルを作成し、分類モデルの評価実験を行った。分類モデルの作成には全て LightGBM を利用している。表 2 に分類モデルに用いる特徴量の一覧およびそ

の組み合わせを示す。また、分類モデルの評価について、以下の 3 つのシステム利用状況を想定して分類モデルの作成および評価を行った。

#### ユーザのキャストデータが未知の場合

ユーザのキャスト分類には既に存在する汎用分類モデルが用いられることを想定している。つまり、システム利用ユーザのキャストデータを分類モデルの学習に使用することなく、ユーザのキャスト動作を分類可能かどうかを調査する。

#### ユーザのキャストデータが一部既知の場合

ここでは、ユーザが予め自身のキャスト動作のデータを登録した上で、分類モデルを学習および運用することを想定している。システムを利用するユーザのキャストデータの一部を分類モデルの学習に使用することで、分類精度の向上に寄与するかを調査する。

#### 分類においてリアルタイム性を考慮した場合

ここでは、バックラッシュ防止に向けたブレーキ機能の自動調整を想定している。ベイトリールを利用する際、スプールの回転速度と釣糸が出る速度の均衡が崩れると、バックラッシュと呼ばれる糸が絡まる現象が起きる。ベイトリールにはバックラッシュを防ぐために、スプールの回転を制御するブレーキ機構が備わっているが、調整は手動で行う必要がある。そのため、キャストの瞬間に瞬時にキャストの種類を分類することが可能になると、キャストの種類に沿った適切なブレーキ設定を自動で制御し、バックラッシュの防止に繋がると考えられる。

以下の項でそれぞれの想定したシステム利用状況について評価方法および結果を示す。

##### 4.3.1 ユーザのキャストデータが未知の場合

ここでは、オーバーヘッドキャスト、サイドキャスト、ピッチングの 3 分類タスクを行った。特徴量の組み合わせについては、表 2 における組み合わせ (I) を用いた。キャスト分類モデルの評価においては、Leave-One-Person-Out 交差検証を行い、正解率・再現率・適合率・F 値を算出した。表 3 に評価結果を示す。

##### 4.3.2 ユーザのキャストデータが一部既知の場合

ここでは、「学習用データに加えるキャストの回数」と「分類モデルの学習方法」の組み合わせによって分類精度の変化を調べた。ここで、「学習用データに加えるキャストの回数」を  $n$  と置く。例として  $n = 3$  の場合、検証用となるユーザのデータからオーバーヘッドキャスト・サイドキャスト・ピッチングから各 3 投ずつ、合計 9 投のキャストデータを取り出して学習用データに加えることを意味する。また、学習方法については以下の通りである。

#### 前提

表 2: 分類モデルに用いる特徴量および組み合わせ

特徴量	詳細	組み合わせ		
		(I)	(II)	(III)
distance	飛距離	✓		
pre_datalength	precast のデータ長	✓		
post_datalength	cast のデータ長	✓		
cast_time	キャスト時間	✓		
accelX_max	X 軸加速度	最大値	✓	✓
accelX_min		最小値	✓	✓
accelX_mean		平均値	✓	✓
accelX_var		分散	✓	✓
accelY_max	Y 軸加速度	最大値	✓	✓
accelY_min		最小値	✓	✓
accelY_mean		平均値	✓	✓
accelY_var		分散	✓	✓
accelZ_max	Z 軸加速度	最大値	✓	✓
accelZ_min		最小値	✓	✓
accelZ_mean		平均値	✓	✓
accelZ_var		分散	✓	✓
accelR_max	合成加速度	最大値	✓	✓
accelR_min		最小値	✓	✓
accelR_mean		平均値	✓	✓
accelR_var		分散	✓	✓
gyroscopeX_max	X 軸角速度	最大値	✓	✓
gyroscopeX_min		最小値	✓	✓
gyroscopeX_mean		平均値	✓	✓
gyroscopeX_var		分散	✓	✓
gyroscopeY_max	Y 軸角速度	最大値	✓	✓
gyroscopeY_min		最小値	✓	✓
gyroscopeY_mean		平均値	✓	✓
gyroscopeY_var		分散	✓	✓
gyroscopeZ_max	Z 軸角速度	最大値	✓	✓
gyroscopeZ_min		最小値	✓	✓
gyroscopeZ_mean		平均値	✓	✓
gyroscopeZ_var		分散	✓	✓
gyroscopeR_max	合成角速度	最大値	✓	✓
gyroscopeR_min		最小値	✓	✓
gyroscopeR_mean		平均値	✓	✓
gyroscopeR_var		分散	✓	✓

表 3: ユーザのキャストデータを学習に使用しない場合の分類評価結果

検証方法	評価指標 (%)			
	正解率	再現率	適合率	F 値
LOPO**	86.9	86.9	87.6	87.3

\*\* Leave-One-Person-Out

Leave-One-Person-Out 交差検証を行う際に、ユーザー一人分を除いたデータによって学習された分類モデルを model 1 とする。

#### 学習方法 1

検証用となるユーザのデータの一部を学習用とし、残りを検証用とする。既に学習済みである model 1 を用

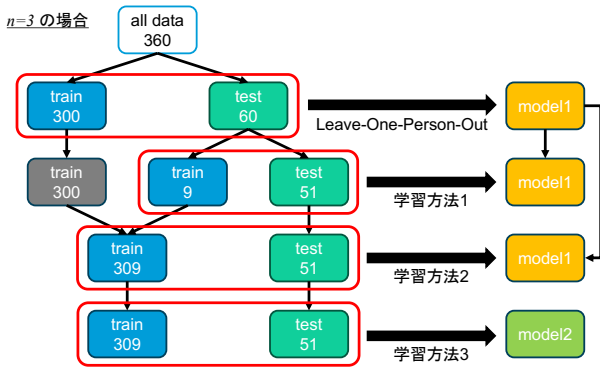


図 7: 分類モデルの学習方法の概要

いて追加学習および検証を行う。

### 学習方法 2

検証用となるユーザのデータの一部を他のユーザデータに加えて学習用データとし、残りを検証用とする。既に学習済みである model 1 を用いて追加学習および検証を行う。

### 学習方法 3

学習方法 2 で作成した学習用データと検証用データを用いて、新たに分類モデルを構築する。このモデルを model 2 とする。

図 7 に  $n = 3$  の場合における分類モデルの学習方法の概要を示す。4.3.1 項と同様に、オーバーヘッドキャスト、サイドキャスト、ピッチングの 3 分類タスクを行った。特徴量の組み合わせについては、表 2 における組み合わせ (I) を用いた。キャスト分類モデルの評価においては、Leave-One-Person-Out 交差検証を行い、比較対象として Leave-One-Session-Out 交差検証も行った。表 4 に評価結果を示す。

#### 4.3.3 分類においてリアルタイム性を考慮した場合

ここでは、オーバーヘッドキャスト、サイドキャスト、ピッチングの 3 分類タスクを行った。また、飛距離が同等であるオーバーヘッドキャストとサイドキャストを 1 つのクラスとみなし、ピッチングを別のクラスとして 2 分類タスクを行った。特徴量として、表 2 における組み合わせ (I)・(II)・(III) の精度を比較した。ここで、組み合わせ (II) は (I) から飛距離といったスプールの回転が停止するまで得られない特徴量を除いたものである。また、(II I) は (II) から更に合成加速度・合成角速度から得られる基本統計量を除いたものである。キャスト分類モデルの評価においては、Leave-One-Session-Out 交差検証および Leave-One-Person-Out 交差検証を行った。表 5 に評価結果を示す。

### 4.4 結果のまとめと考察

検証の結果、4.3.2 項および 4.3.1 項より、Leave-One-

表 4: ユーザのキャストデータの一部を学習に使用した場合の分類評価結果

(a) Leave-One-Session-Out 交差検証の結果

検証方法	評価指標 (%)			
	正解率	再現率	適合率	F 値
LOSO*	98.1	98.1	98.1	98.1

(b) 学習方法 1 の結果

検証方法	$n$	評価指標 (%)			
		正解率	再現率	適合率	F 値
LOPO**	1	87.4	87.4	88.1	87.8
	2	87.7	87.7	88.4	88.0
	3	87.9	87.9	88.8	88.3

(c) 学習方法 2 の結果

検証方法	$n$	評価指標 (%)			
		正解率	再現率	適合率	F 値
LOPO**	1	76.0	76.0	76.4	76.2
	2	80.3	80.3	82.6	81.4
	3	83.7	83.7	86.5	85.1

(d) 学習方法 3 の結果

検証方法	$n$	評価指標 (%)			
		正解率	再現率	適合率	F 値
LOPO**	1	92.1	92.1	92.9	92.5
	2	95.4	95.4	95.6	95.5
	3	96.1	96.1	96.2	96.1

\* Leave-One-Session-Out

\*\* Leave-One-Person-Out

Session-Out 交差検証において正解率 98.1%、F 値 98.1%、Leave-One-Person-Out 交差検証において正解率 86.9%、F 値 87.3% の精度を記録した。同様に 4.3.2 項より、ユーザの 3 種類のキャストを各 3 投ずつ合計 9 投を学習に加えて分類モデルを一から学習することで、Leave-One-Person-Out 交差検証において正解率 96.1%、F 値 96.1% の精度を記録した。検証用のユーザデータを学習用に追加しなかった時と比較して約 10% 精度が向上したことから、システムの利用の際にユーザのキャストデータを登録して分類モデルを学習することで、より高い精度でキャスト分類を実現できることが示唆された。

4.3.3 項においてキャスト 3 分類の結果より、飛距離のデータや合成加速度・合成角速度から得られる特徴量を利用した場合と比較して、リアルタイム性を考慮して 3 軸加速度および 3 軸角速度から得られる特徴量のみを利用してキャスト 3 分類の精度には大きく影響していないことがわかった。また、キャスト 2 分類の結果より、Leave-One-Session-Out 交差検証および Leave-One-Person-Out 交差検証の両方においてキャスト 3 分類の精度を上回る結果となった。比較的飛距離が出やすいオーバーヘッドキャスト

表 5: リアルタイム性を考慮したキャスト分類の評価結果

(a) キャスト 3 分類の結果

検証方法	C***	評価指標 (%)			
		正解率	再現率	適合率	F 値
LOSO*	(I)	98.1	98.1	98.1	98.1
	(II)	98.3	98.3	98.3	98.3
	(III)	98.3	98.3	98.3	98.3
LOPO**	(I)	86.9	86.9	87.6	87.3
	(II)	85.0	85.0	85.8	85.4
	(III)	86.9	86.9	87.4	87.2

(b) キャスト 2 分類の結果

検証方法	C***	評価指標 (%)			
		正解率	再現率	適合率	F 値
LOSO*	(I)	98.9	98.8	98.8	98.8
	(II)	98.9	98.8	98.8	98.8
	(III)	98.9	98.8	98.8	98.8
LOPO**	(I)	91.4	91.0	89.9	90.5
	(II)	91.7	90.6	90.6	90.6
	(III)	92.5	91.7	91.5	91.6

\* Leave-One-Session-Out

\*\* Leave-One-Person-Out

\*\*\* 特徴量の組み合わせ

ト・サイドキャストと、飛距離が出にくいピッチングとの比較のため、飛距離が判別に大きく寄与していると考えられるが、飛距離のデータを含まない組み合わせである (II)・(III) でも同様の精度が得られている。これは図 6 を見る限り、ピッチングは他の 2 種類のキャストと比較して Z 軸方向の角速度がマイナス方向に突出しておらず、分類に有利に働いたからであると考えられる。ただし、ラベル別データ数がキャスト 2 分類では 2:1 と偏りがあるため、過学習が生じている可能性がある。

## 5. おわりに

本稿では、釣り上達支援システムを提案し、システムの実現に向けて基本的な動作であるキャストに着目し、3 種類のキャスト（オーバーヘッドキャスト・サイドキャスト・ピッチング）を機械学習を用いて分類するモデルを構築した。分類モデルの構築のため、被験者 6 名からキャスト動作のデータ（加速度、角速度、飛距離など）を収集した。得られたデータから加速度および角速度の基本統計量（最大・最小・平均・分散）を導出し、LightGBM を用いて分類モデルを構築した。分類モデルの評価を行い、Leave-One-Session-Out 交差検証において正解率 98.1%、F 値 98.1% の精度を、Leave-One-Person-Out 交差検証において正解率 86.9%、F 値 87.3% の精度を確認した。加えて、ユーザが予め自身のキャスト動作のデータを登録した上で、分類モデルを学習および運用することを想定し

た。Leave-One-Person-Out 交差検証において検証用となるユーザデータの一部を学習用データに追加し、分類モデルを一から学習して検証を行った結果、最大で正解率 96.1%、F 値 96.1% の精度を確認した。検証により、高い精度でキャストを分類できること、および判別対象のユーザデータを追加して分類モデルを学習することで、より高い精度でキャストを分類できることが確認できた。

今後の展望として、今回は提案システムにおいてキャスト分類に留まっていることから、ユーザへのフィードバックに向けたキャストの評価について検討していく必要がある。

## 参考文献

- [1] 公益財団法人日本生産性本部：レジャー白書 2021.
- [2] 株式会社スマートルアー：smartLure Model Zero guides your fishing tactics work best. <https://www.kickstarter.com/projects/smartlure/smartlure-model-zero>.
- [3] 株式会社 BalticVision：Deeper 魚群探知機の日本代理店の公式ショップ. <https://deepersonar.jp/>.
- [4] 不破茂, 山口祐輔, 江幡恵吾, 藤田伸二：ルアー釣り動作の解析, 日本水産工学会 学術講演会 学術講演論文集 2014 年度 日本水産工学会 学術講演会 講演論文集, 日本水産工学会, pp. 123-126 (2014).
- [5] 福田修之, 松井智一, 松田裕貴, 安本慶一ほか：釣果情報共有を目的とした釣竿の振動データに基づく魚種判別手法, 第 28 回マルチメディア通信と分散処理ワークショップ論文集, pp. 19-26 (2020).
- [6] 福田修之, Hong, S., Oh, H., Choi, H., 松田裕貴, 安本慶一：釣竿に取り付けた慣性センサを用いた釣人の行動認識, 海洋理工学会大会講演論文集集, Vol. 2019, No. 秋季, pp. 60-63 (2019).
- [7] 福田修之, 玉置理沙, 松井智一, 大井一輝, 松田裕貴, 安本慶一ほか：リアルタイム行動認識機能を有する釣り CPS の開発, 第 28 回マルチメディア通信と分散処理ワークショップ論文集, pp. 172-179 (2020).
- [8] 難波亮也, 山崎大河, 泉晋作ほか：釣りのルアーキャストにおける飛距離の解析, 人間工学, Vol. 58, No. Supplement, pp. 2E5-02 (2022).
- [9] Blank, P., Hoßbach, J., Schuldhau, D. and Eskofier, B. M.: Sensor-based stroke detection and stroke type classification in table tennis, *Proceedings of the 2015 ACM International Symposium on Wearable Computers*, pp. 93-100 (2015).
- [10] Torigoe, Y., Nakamura, Y., Fujimoto, M., Arakawa, Y. and Yasumoto, K.: Strike Activity Detection and Recognition Using Inertial Measurement Unit towards Kendo Skill Improvement Support System., *Sensors & Materials*, Vol. 32 (2020).
- [11] Nakamura, Y., Arakawa, Y., Kanehira, T., Fujiwara, M., Yasumoto, K. et al.: Sensstick: Comprehensive sensing platform with an ultra tiny all-in-one sensor board for iot research, *Journal of Sensors*, Vol. 2017 (2017).
- [12] Berndt, D. J. and Clifford, J.: Using dynamic time warping to find patterns in time series, *Proceedings of the 3rd international conference on knowledge discovery and data mining*, pp. 359-370 (1994).
- [13] 鳥越庸平, 中村優吾, 藤本まなと, 荒川豊, 安本慶一：剣道上達支援システムの実現に向けたウェアラブルセンサによる打突動作の熟練度評価, 社会システムと情報技術研究ウィーク (2020).