

ウェアラブル慣性センサを用いた バレーボール選手のレシーブ得意・不得意コース認識システムの検討

A Preliminary Study on Classifying Volleyball Dig Success Across Spike Directions Using Wearable Inertial Sensors

阪本 藻太[†] 松田 裕貴[†]
Sota Sakamoto Yuki Matsuda

1 はじめに

バレーボールにおけるスパイクレシーブ（ディグ）は、相手スパイクを防ぎ、攻撃へつなげるための重要な基本技術である [1]。しかし、実際の競技では、レシーバーがどこに立ち、どの範囲を守るべきかといった守備位置（ポジショニング）は、選手や指導者の経験や感覚に基づいて決定されることが多く [2]、客観的な指標に基づく支援手法は十分に確立されていない。

実際のポジショニングでは、相手スパイカーの助走や攻撃方向、ブロッカーの位置、味方選手との守備範囲など、多くの要因を考慮する必要がある。また、同じ選手であっても、スパイクが打たれるコースによってレシーブの成功率が異なることが競技経験から知られている。実際に、樋口ら [3] はレシーバーごとに守備範囲が違うことを示している。このような個人ごとの得意・不得意コースを定量的に把握できれば、選手ごとに適した守備位置を提案できる可能性がある。本研究の最終目標は、各選手の得意・不得意コースを推定し、その結果に基づいて最適な守備位置および守備隊形を提案するシステムを構築することである。その実現には、まずレシーブ動作から成功・失敗を判定できるモデルを構築する必要がある。

本研究では、スパイカーおよびレシーバーの双方にウェアラブル慣性センサを装着して身体運動データを取得し、そのデータを用いてレシーブ成功・失敗判定モデルを構築する（図 1）。さらに、判定性能および特徴量重要度の分析を通じて、選手ごとのレシーブ特性を明らかにし、将来的な守備位置提案へつなげることを目指す。

ウェアラブル慣性センサを用いた計測方法、スパイクタイミング検出手法、特徴量抽出および LightGBM^{*1}を用いた成功・失敗判定手法について述べ、実験を通して提案手法の有効性を検証する。レシーブ動作はスパイクコースに応じて身体運動や難易度が異なると想定されるため、スパイクコースを Left, Center, Right の 3 種類に分類した。コースごとに成功・失敗判定モデルを構築することで、コースごとの判定性能を比較する。これに

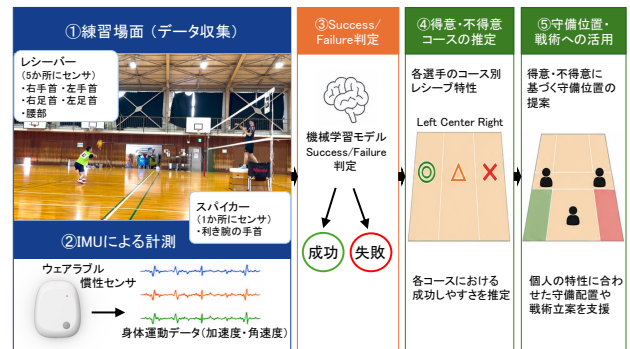


図 1: 本研究の全体像

より、将来的な守備位置提案に向けて、選手ごとの得意・不得意コースを定量的に把握できる可能性を検討する。

2 関連研究

2.1 バレーボールにおける動作・戦術解析

バレーボールでは、競技力向上や戦術構築を目的として、試合映像や競技記録を用いた技術・戦術解析が数多く行われている。以下の研究は、試合映像または競技記録を用いたものである。

Priatmojo ら [4] は、クラブレベルの選手を対象にレシーブ精度と攻撃成功率との関係进行分析し、レシーブ精度の向上が攻撃機会の質を高めることを報告している。Drikos ら [5] は、試合データからレシーブ品質と攻撃結果との関係进行分析し、高品質なレシーブほど攻撃成功率が高くなることを示した。Millán-Sánchez ら [6] は、レシーブ品質がセッターの移動を抑え、多様な攻撃戦術の選択につながることを報告している。Paulo ら [7] は、レシーバーの初期位置や移動特性からサーブレシーブ結果を予測し、競技データを用いた客観的な評価の可能性を示した。国内では、柿島ら [8] が男子バレーボールのサイドアウト局面を分析し、レシーブ品質が攻撃展開や得点獲得に影響することを示している。また、森ら [9] は、大学女子バレーボールのディグ動作を分析し、攻撃種類に応じた安定したレシーブ動作が成功率に関係することを報告している。

これらの研究によりレシーブ品質の重要性は明らかにされているが、多くは映像解析や試合統計に基づくもの

[†] 岡山大学, Okayama University

^{*1} <https://lightgbm.readthedocs.io/en/stable/>

であり、身体運動データを用いてレシーブの成否を直接判定する研究は少ない。

2.2 ウェアラブルセンサを用いたスポーツ動作解析

IMU (Inertial Measurement Unit) を搭載するウェアラブルデバイスによるセンシング、および機械学習を用いたスポーツ動作解析が行われている。

Wang ら [10] は、手首装着型の慣性センサから取得した加速度・角速度データを用いてスパイク技能を評価し、機械学習による技能レベル分類の有効性を示した。Haider ら [11] は、複数のウェアラブルセンサと Super-Bagging 法を用いてバレーボール動作を高精度に認識している。Jauhainen ら [12] は、IMU から取得した加速度・角速度データを用いてバレーボールのジャンプ動作を分類し、ウェアラブルセンサと機械学習の有効性を示した。Nako ら [13] は、レシーブ映像を対象に深層学習による階層型分類を行い、レシーブ品質の自動評価手法を提案している。Jia [14] は、ウェアラブル生体センサで取得した身体情報と競技パフォーマンスとの関係を分析し、ウェアラブルセンサの有用性を報告している。この他にも、ジャンプ動作を対象としウェアラブルセンサによる競技動作認識 [15] も行われており、ウェアラブルセンサを用いて試合中の生体情報や身体負荷を計測し、競技パフォーマンスとの関係を分析する研究も進められている。

これらの研究では、競技動作やレシーブ品質の評価が行われているが、ウェアラブル慣性センサのみを用いてスパイクコースごとのレシーブ成功・失敗を判定した研究は十分に行われていない。

2.3 本研究の位置付け

従来研究では、映像解析やウェアラブルセンサを用いた動作解析、機械学習によるスポーツ動作認識などが数多く報告されている。しかし、複数台のウェアラブル慣性センサから取得した身体運動データのみを用いてレシーブの成功・失敗を判定し、さらにスパイクコースごとに判定性能や重要特徴量を比較した研究は、著者らの知る限り報告されていない。

本研究では、ウェアラブル慣性センサから取得した身体運動データを用いてレシーブ成功・失敗判定モデルを構築する。さらに、全コースおよびスパイクコース別の判定性能を評価するとともに、各モデルの特徴量重要度を比較することで、コースごとのレシーブ動作の特徴を分析する。これらの分析を通じて、選手のコースごとのレシーブ特性を定量的に評価し、将来的な個人適応型の守備位置および守備隊形の提案につながる基礎的知見を得ることを目的とする。




図 2: ウェアラブル慣性センサを用いたレシーブ成功・失敗判定システムの概要

3 提案手法

3.1 システム概要

ウェアラブル慣性センサから取得した時系列データを用いて、レシーブ成功・失敗を判定する機械学習モデルを構築する。提案システムの概要を図2に示す。提案システムは、時系列データの計測、スパイクタイミング推定、データ前処理、特徴量抽出、およびLightGBMによる分類の5つの処理から構成される。

データ切り出しにおいて、スパイクタイミングを基準として各試行の時系列データを生成し、特徴量を抽出することで、レシーブ成功・失敗を判定する。なお、本研究では分類性能の評価を目的とするため、実験時には実験映像を用いてスパイク時刻の確認およびスパイクコース・レシーブ成否のアノテーションを行った。LightGBMによる分類では、映像データを用いていない。

3.2 センサ構成

本研究では、競技中の自然な身体運動を妨げることなくレシーブ動作を計測するため、小型で軽量のウェアラブル慣性センサ MetaMotionS^{*2}を用いた。MetaMotionSは3軸加速度および3軸角速度を計測可能なウェアラブル慣性センサであり、スパイクレシーブのような短時間の身体運動を高い時間分解能で計測できる。また、各センサは計測開始時にデータ取得開始を指示するPCとの時刻同期を行うため、センサ間での時刻同期が容易であり、複数部位の運動を同一時間軸上で解析できる。本稿では、サンプリング周波数は100Hzに設定した。

レシーブ動作は、下肢による移動、体幹による重心移動、上肢によるボール操作から構成されることから、スパイクの利き腕の手首に1か所、レシーバーの両手首、両足、腰の計5か所にそれぞれMetaMotionSを装着した(図3)。両足・腰のセンサ装着には著者らが設計した3Dプリンタ治具[16]を用い、手首のセンサ装着には新たに設計した3Dプリンタ治具を用いた。各センサが

^{*2}<https://mbientlab.com/metamotions/>



図 3: MetaMotionS の装着位置。手首には伸縮バンド、腰にはクリップ、靴には靴紐を用いて固定した。




図 4: スパイクタイミング検出アルゴリズムの処理フロー

ら取得した 3 軸加速度および 3 軸角速度の時系列データを解析対象とし、スパイクの利き腕の手首のセンサはスパイクタイミングの推定、レシーバーの両足は移動動作、腰は身体の重心移動、両手首はレシーブ時の上肢動作を取得するために用いた。

3.3 スパイクタイミング検出

スパイクタイミング検出処理の流れを図 4 に示す。各試行を同一の基準時刻で切り出すため、スパイクの利き腕の手首に装着した MetaMotionS から取得した慣性センサデータを用いてスパイクタイミングを推定した。

スパイクタイミングを検出するための具体的な計算処理を述べる。スパイクの 3 軸加速度および 3 軸角速度から、それぞれの合成加速度および合成角速度を式 (1) および式 (2) により算出した。

$$a(t) = \sqrt{a_x(t)^2 + a_y(t)^2 + a_z(t)^2} \quad (1)$$

$$\omega(t) = \sqrt{\omega_x(t)^2 + \omega_y(t)^2 + \omega_z(t)^2} \quad (2)$$

続いて、合成加速度と合成角速度を用いてインパクトスコアを式 (3) により算出した。

$$S_{\text{impact}}(t) = a(t) \times \omega(t) \quad (3)$$

算出したインパクトスコアおよび合成加速度に対して閾値判定を行い、スパイク候補を抽出した。候補が複数検出された場合は、ピーク値およびピーク間隔を考慮してスパイクタイミングを決定した。閾値は、事前に取得した波形を確認し、スパイク動作を他の身体動作と識別できる値となるよう経験的に設定した。

3.4 データ前処理・アノテーション

取得した連続時系列データから機械学習に用いる試行データを生成するため、前処理およびアノテーションを行った。まず、3.3 節で推定したスパイクタイミングを基準として、スパイク前 0.5 秒からスパイク後 1.0 秒までの計 1.5 秒間を 1 試行の時系列データとして切り出した。次に、各試行に対してスパイク時刻の確認およびスパイクコース・レシーブ成否のアノテーションを行った。スパイクコースは左側 (以下, Left), 正面 (以下, Center), 右側 (以下, Right) の 3 種類に分類した。

レシーブ成否の評価基準を以下に示す。サーブレシーブ評価について、国内競技会 [17] では成功 (優), 成功 (良), 失敗の 3 段階評価が用いられている。また、世界的なスカウティングソフトウェアとして広く利用されている DataVolley [18] で使われている A~D の 4 段階で評価する場合もある。そこで本研究では、DataVolley の評価基準をスパイクレシーブへ適用することを検討した。レシーブ品質の違いをより詳細に評価するため、DataVolley の評価基準を拡張し、表 1 に示す通り 8 段階の評価基準を定義した。また、レシーブ動作の成功・失敗判定にあたっては、A~B- を Success (成功), C~D を Failure (失敗) とし、ボールに触れることができなかった D- (Miss) は学習データセットから除外した。これは、本稿ではレシーブ成功・失敗判定モデルを構築することを目的とし、ボールへの接触を伴う試行を対象とした 2 値分類問題として扱うためである。一方で、本研究で構築した 8 段階の評価基準は、今後、各評価段階を分類対象としたレシーブ品質推定モデルへの拡張を想定している。

取得した時系列データに対しては、平滑化やフィルタ処理などの前処理は行わず、計測データをそのまま用いた。また、欠損値を含む試行は特徴量抽出時のエラーを防ぐため、データセットから除外した。

3.5 特徴量抽出方法

3.4 節で生成した各試行の時系列データから、特徴量抽出ライブラリ tsfresh^{*3} を用いて特徴量を抽出する。特徴量抽出のパラメータは EfficientFCParameters を用いる。各試行の時系列データを tsfresh で利用可能な Long-format へ変換し、各種統計量に基づく特徴量を抽出する。

^{*3} <https://tsfresh.readthedocs.io/en/latest/>

表 1: レシーブ評価基準と対応関係

DataVolley [18] (既存の評価基準)	本研究の 評価基準	判定基準の説明
A	A	セッターの定位置付近へ返球され、全ての攻撃パターンを選択可能な場合
B	B+ (細分化)	全ての攻撃パターンを選択可能であるが、Aと比較してセッターの移動または姿勢の調整を要する場合
	B (細分化)	セッターから約1~3m以内のアタックゾーンへ返球され、ほぼ全ての攻撃パターンを選択可能な場合
	B- (細分化)	セッターによるトスは可能であるが、速攻や平行トスなど一部の攻撃が制限される場合
C	C	返球が乱れ、限定的な攻撃しか選択できない場合、またはセッター以外の選手が二段トスを行うことが適切な場合
D	D+ (細分化)	ボールは返球されたものの、相手コートへ直接返球された場合、又は自コート外へ返球され、攻撃へ移行できない場合
	D (細分化)	ボールには触れたものの、返球が成立せず、味方選手による継続プレーが困難な場合
	D- (細分化)	ボールに触れることができず、ボールが直接コートへ落下した場合 (Miss)




図 5: 提案する 2 種類の特徴量抽出方法（手法 1：全区間特徴量抽出，手法 2：前後分割特徴量抽出）の概要

本研究では、スパイク前後の時系列情報の扱い方に着目し、比較検討のために次に示す 2 種類の特徴量抽出方法を提案する（図 5）。

- **手法 1（全区間特徴量抽出）**：スパイク前 0.5 秒からスパイク後 1.0 秒までの 1.5 秒間の時系列データ全体を 1 つの系列として扱い、特徴量を抽出する
- **手法 2（前後分割特徴量抽出）**：同一の時系列データをスパイク前 0.5 秒間とスパイク後 1.0 秒間に分割し、それぞれの区間から特徴量を抽出した後、両者を横方向に連結して 1 つの特徴ベクトルを生成する

各手法によって抽出された特徴量に対しては、事前の特徴量選択や次元削減は行わず、抽出された全特徴量を分類モデルへ入力する。

3.6 成功・失敗判定モデル（LightGBM）

tsfresh により抽出した特徴量を入力とし、レシーブ動作を Success または Failure の 2 クラスへ分類する機械学習モデルを構築した。分類器としては、勾配ブー

スティング決定木に基づく機械学習アルゴリズムであり、高次元の特徴量に対して効率的に学習できる特徴量を有する LightGBM を用いた。モデルは tsfresh によって抽出された特徴量を入力することで学習し、小規模データセットに対応するため、LightGBM のパラメータ `min_data_in_leaf` は 1 に設定した。その他の主要なパラメータはデフォルト設定とし、乱数シードは 42 に固定した。

4 実験概要・評価方法

本実験は、岡山大学教育学部体育館内のバレーボールコートにおいて実施した（図 6）。実験には、スパイカー 1 名（22 歳男性、バレーボール経験 9 年、岡山大学男子バレーボール部所属）およびレシーバー 1 名（21 歳男性、バレーボール経験 10 年、同部所属）が参加した。両被験者には、3.2 節で示した MetaMotionS を装着させた。

実験では、スパイカーがスパイク台の上からレシーバーの Left、Center および Right の 3 方向ヘランダムにスパイクを行い、レシーバーは試合を想定した待機姿勢からレシーブを行った。この時、試行中の動作確認および分析のため、全試行において実験映像を撮影した。

各試行において MetaMotionS から取得した慣性センサデータおよび実験映像に対し、第 3 章で述べた手法に従ってスパイクタイミング検出、前処理、特徴量抽出および分類モデルの構築を行った。本研究ではレシーブ成功・失敗判定モデルの性能評価を目的としたため、スパイクタイミング検出アルゴリズム自体の評価は行っていない。そのため、各試行の時系列データの切り出しには、実験映像を用いて確認したスパイク時刻を基準として用いた。また、レシーブ成否およびスパイクコースについても実験映像を用いてアノテーションを行った。

モデルの評価には Leave-One-Trial-Out Cross Validation (LOTO-CV) を用いた。LOTO-CV では、各試行を 1 回ずつテストデータとし、残りの試行を学習データとしてモデルを学習する。つまり、全 306 試行を対象とした 306-fold の交差検証を行った。加えて、各コースについても同様にコースごとに LOTO-CV を実施した。性能評価指標には Accuracy, Precision, Recall および F1-score を用いた。また、分類結果の傾向を分析するため混同行列を、モデルが重視した特徴量を分析するため特徴量重要度を用いた。

本研究で構築したデータセットは、全 306 試行から構成される。その内訳は Success が 192 試行、Failure が 114 試行である。各コースの試行数を表 2 に示す。Success と Failure の試行数に偏りがあるため、学習時には多数クラスをランダムに削減するランダムアンダーサンプリングを行い、訓練データのクラス数を均衡化した。



図 6: 実験環境（バレーボールコート、カメラおよびスパイク台）

表 2: データセットの構成

コース	Success	Failure	合計
Left	54	39	93
Center	88	26	114
Right	50	49	99
合計	192	114	306

5 実験結果・考察

本章では、提案手法によるレシーブ成功・失敗判定の結果を示す。まず、特徴量抽出方法の違いによる分類性能を比較する。次に、全試行を対象とした Success/Failure 分類結果を示し、その後、スパイクコースごとの分類結果について比較する。最後に、これらの結果から提案手法の有効性および課題について考察する。

5.1 特徴量抽出方法の比較

3.5 節で提案した 2 種類の特徴量抽出方法（手法 1: 全区間特徴量抽出、手法 2: 前後分割特徴量抽出）ごとの評価結果を表 3 に示す。全コースでは、手法 2 が Accuracy 58.8%, Weighted Average F1-score 60.0% となり、手法 1 より高い分類性能を示した。一方、Center コースおよび Right コースでは手法 1、Left コースでは手法 2 がわずかに高い分類性能を示した。このことから、時間区間の分割効果は分類対象によって異なることが分かった。

全コースおよび Left コースでは、スパイク前後を分割して特徴量化することで、各時間区間に含まれる運動情報を個別に表現でき、分類性能の向上につながった可能性がある。一方、Center コースおよび Right コースでは、時系列全体を一括して特徴量化する方が、運動の連続性を保持できたため有効であった可能性がある。

以上より、時間区間の分割がすべての条件で有効とは限らないものの、全コースでは最も高い分類性能を示したことから、以降では、スパイク前後を分割して特徴量を抽出する手法 2 を用いて、実験および考察を行う。




図 7: 全試行におけるレシーブ成否分類結果の混同行列

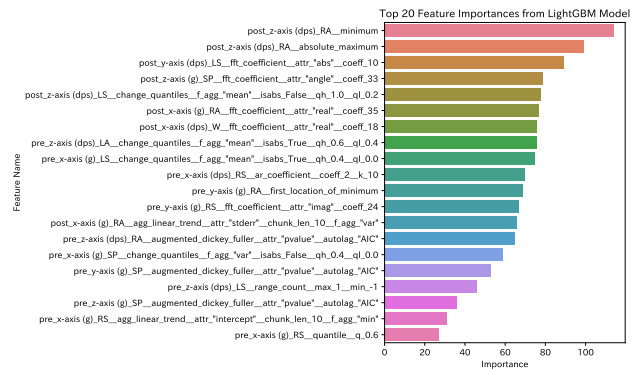


図 8: 全試行における特徴量重要度の上位 20 位

5.2 全コースを対象とした Success/Failure 分類

5.1 節で採用した特徴量抽出手法 2 を用いて、全 306 試行を対象とした Success/Failure 分類を行った。混同行列を図 7 に、特徴量重要度上位 20 特徴量を図 8 に示す。

分類性能は Accuracy 58.8%, Weighted Average F1-score 60.0% であった。混同行列（図 7）より、Success 試行を Failure と誤分類する傾向が見られ、Success クラスの Recall は 58.0% に留まった。一方、Failure クラスは Recall 61.0% であった。Failure クラスの Recall は Success クラスよりわずかに高かったことから、Failure を識別する情報は比較的捉えられていた可能性がある。

特徴量重要度（図 8）から、レシーバーの右手首（RA）と左足（LS）に由来する特徴量が特に重要であることがわかった。さらに、レシーバーの腰（W）、左手首（LA）、スパイク側センサ（SP）に由来する特徴量も上位に含まれた。このことから、レシーバー自身の身体運動だけでなく、相手スパイク動作に関する情報も Success/Failure の判定に寄与している可能性が示唆された。

以上より、ウェアラブル慣性センサから取得した身体運動データには、レシーブ成功・失敗を分類するための有用な情報が含まれていることが確認できた。一方で、分類性能は約 6 割に留まっており、特徴量抽出方法や分

表 3: 特徴量抽出手法・分類対象ごとの分類性能 (Precision, Recall, F1-score は weighted average, 単位: %)

分類対象	手法 1 (一括抽出)				手法 2 (前後分割)			
	Accuracy	Precision	Recall	F1-score	Accuracy	Precision	Recall	F1-score
全コース	53.9	56.0	54.0	52.0	58.8	62.0	59.0	60.0
Left	51.6	54.0	52.0	52.0	52.7	55.0	53.0	53.0
Center	52.6	66.0	53.0	56.0	49.1	69.0	49.0	53.0
Right	58.6	59.0	59.0	59.0	52.5	53.0	53.0	52.0




図 9: レシーブ成否分類結果の混同行列 (Left コース)




図 10: レシーブ成否分類結果の混同行列 (Center コース)




図 11: レシーブ成否分類結果の混同行列 (Right コース)

類モデルの改善に加え、重要特徴量と実際の身体動作との対応関係を分析することで、分類性能の向上につながる特徴を明らかにする必要がある。

5.3 コース別 Success/Failure 分類

スパイクコースによってレシーバーの身体運動が異なる可能性があるため、Left, Center および Right の各コースについて個別に Success/Failure 分類を行った。各コースの混同行列を図 9, 図 10, 図 11 に、特徴量重要度を図 12, 図 13, 図 14 に示す。

Left コースでは Accuracy 52.7%, Weighted Average F1-score 53.0% となり, Success 試行を Failure へ誤分類する傾向が見られた (図 9)。このことから, Left コースでは Success を特徴付ける情報を十分に識別できなかった可能性がある。また, 特徴量重要度 (図 12) から, レシーバーの右手首と右足 (RS) に由来する特徴量が特に重要であることがわかった。さらに, レシーバーの左手首, 左足, 腰およびスパイク側センサに由来する特徴量が上位に含まれていた。

Center コースでは Accuracy 49.1%, Weighted Average F1-score 53.0% となり, 3 コースの中で最も低い分類性能となった。混同行列 (図 10) より, Success 試行を Failure へ誤分類する傾向が特に顕著であった。このことから, Center コースでは Success を特徴付ける情報を十分に識別できなかった可能性がある。特徴量重要度 (図 13) では, レシーバーの右手首と右足に加え, スパイク側センサに由来する特徴量も上位に含まれた。

Right コースでは Accuracy 52.5%, Weighted Average F1-score 52.0% となった。混同行列 (図 11) より, Failure 試行を Success へ誤分類する傾向が見られた一方で, Success 試行は比較的識別できていた。このことから, Right コースでは Failure を特徴付ける情報を十分に識別できなかった可能性がある。特徴量重要度 (図 14) から, レシーバーの左右手首と左足に由来する特徴量が重要であることがわかった。

3 コースの分類性能を比較すると, Accuracy および Weighted Average F1-score はいずれも約 50% 程度となり, 大きな差は見られなかった。このことから, スパイクコースごとに分類対象を限定した場合でも, Success と Failure を十分に識別する分類性能は得られなかった。

また, 特徴量重要度 (図 12, 図 13, 図 14) では, すべてのコースでレシーバーの右手首, 左足, 右足, 腰に加え, スパイク側センサ由来の特徴量が重要特徴量として抽出された。このことから, Success/Failure 判定には, レシーバー自身の身体運動だけでなく, 相手スパイク動作も共通して寄与している可能性が示唆された。一方, 各コースで重要となる特徴量の順位や種類には違いが見られたものの, 一貫した傾向は確認できなかった。今後は, 重要特徴量と実際の身体動作との対応関係を動画解析等により検証し, コースごとの Success/Failure を特徴付ける運動特徴を明らかにする必要がある。さらに, 本研究では分類性能の基礎的な検証を目的として Success/Failure の 2 値分類を対象とした。一方, 本研究



図 12: 特徴量重要度の上位 20 位 (Left コース)

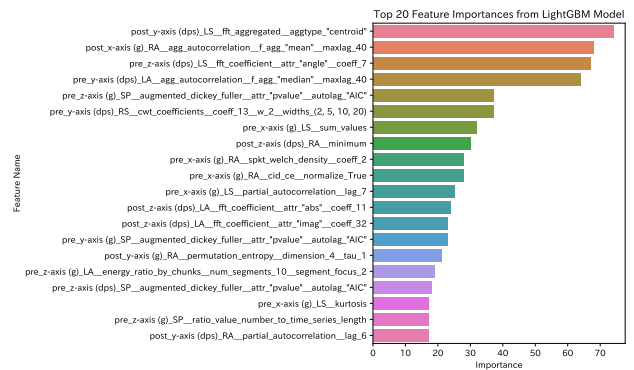


図 14: 特徴量重要度の上位 20 位 (Right コース)

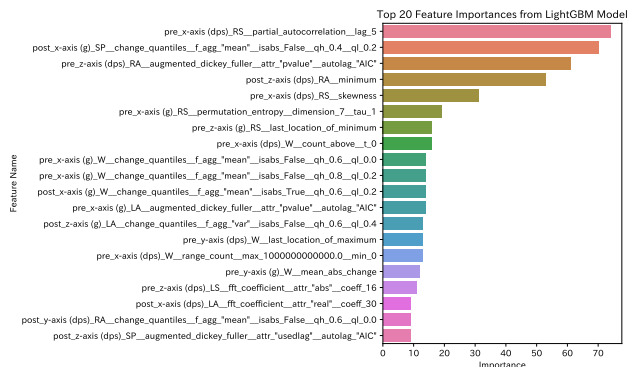


図 13: 特徴量重要度の上位 20 位 (Center コース)

で構築した 8 段階の評価基準は、将来的にレシーブ品質をより詳細に分類するための基盤となる評価基準として位置付けている。今後は、分類性能の向上を図るとともに、各評価段階を対象とした多クラス分類への適用可能性について検討する。

6 おわりに

本研究では、ウェアラブル慣性センサ MetaMotionS を用いて取得した身体運動データから、バレーボールにおけるレシーブ成功・失敗を判定する機械学習モデルを構築した。スパイクの利き腕の手首およびレシーバーの両手首、両足、腰に装着した MetaMotionS から加速度および角速度を取得し、スパイクタイミングを基準とした前後 1.5 秒間の時系列データから特徴量を抽出した。抽出した特徴量を LightGBM へ入力し、全 306 試行を対象として Success/Failure 分類を行った。

特徴量抽出方法の比較では、スパイク前後の時間区間を分割して特徴量化する手法において、全コースを対象とした分類性能が向上した。また、提案手法による Success/Failure 分類では、Accuracy 58.8%, Weighted Average F1-score 60.0%を示した。さらに、スパイクコースごとに分類性能を評価した結果、コースによって分類性能および誤分類の異なる傾向が見られた。このことから、ウェアラブル慣性センサから取得したスパイクおよ

びレシーブ動作の時系列情報には、レシーブ成功・失敗に関連する特徴が含まれている可能性が示された。

また、特徴量重要度の分析では、レシーバーの四肢や体幹に加えて、スパイクの利き腕の手首に装着したセンサに関連する特徴量も分類に利用されていた。本研究では、実際の競技環境に近い条件でのレシーブ評価を目的として、スパイク条件およびレシーバーの身体運動情報を同時に利用した。そのため、得られた分類結果はレシーバーの動作だけでなく、相手スパイクの運動条件を含めた総合的な特徴を反映したものであると考えられる。

一方で、本研究では単一のスパイクおよびレシーバーを対象とした予備的な実験であり、取得データ数や対象者数には限りがある。また、今回の分類ではスパイク条件とレシーバー動作を分離せずに利用しているため、成功・失敗に影響するレシーバー自身の身体動作特徴を個別に評価するまでには至っていない。今後は、複数選手を対象としたデータ収集を行うとともに、レシーバー側センサのみを用いた分類との比較や、重要特徴量と実際の身体動作との関係进行分析することで、成功につながるレシーブ動作の特徴を明らかにする必要がある。

さらに、スパイクコースごとの Success/Failure 判定結果を蓄積することで、選手ごとの得意・不得意コースの定量的な把握へ発展させることが期待される。将来的には、得られたコース別のレシーブ特性と選手位置情報などを組み合わせることで、個人の能力に応じた守備位置や守備隊形を提案する支援システムの構築を目指す。

謝辞 本研究の一部は、JSPS 科研費 (26K21206) の助成を受けて行われたものです。

参考文献

- [1] 山本健之, 縄田亮太, 山田快. 高速度スパイクに対するディグ方法の提案. スポーツパフォーマンス研究, Vol. 8, pp. 335–342, 2016.

- [2] 岡山県バレーボール協会. バレーボール競技一貫指導カリキュラム, 2023. <https://oka-vball.com/kyouka/curriculum.pdf>, Accessed: 2026-07-24.
- [3] 樋口好彦, 中井一文, 重永貴博, 江崎修央. バレーボールのサーブレシーブの守備範囲推定に関する検討. 情報処理学会第 83 回全国大会講演論文集, 第 2021 巻, pp. 243–244, 2021.
- [4] Hanif Priatmojo, I Utamayasa, Angga Kusuma, Santika Hadi, Hayati Hayati, Adim Epostam, and Mohammad Zen. The Relationship Between Passing Accuracy and On-Point Passing Skills Among Amateur Club-Level Volleyball Players. *JSES : Journal of Sport and Exercise Science*, Vol. 9, pp. 29–38, 2026.
- [5] Sotirios Drikos. Pass level and the outcome of attack for age categories in male Volleyball. *PANR Journal*, pp. 428–438, 2018.
- [6] Antonio Millán-Sánchez, Manuel Parra-Royón, José Benítez, and Aurelio Ureña Espa. Ability to Predict Side-Out Performance by the Setter's Action Range with First Tempo Availability in Top European Male and Female Teams. *International Journal of Environmental Research and Public Health*, Vol. 17, p. 6326, 2020.
- [7] Ana Paulo, Frank T. J. M. Zaal, Sofia Fonseca, and Duarte Araújo. Predicting Volleyball Serve-Reception. *Frontiers in Psychology*, Vol. 7, pp. 1–9, 2016. Article No. 1694.
- [8] 柿島新太郎, 増山光洋, 佐藤浩明. バレーボールゲームにおけるサイドアウト局面に関する研究. 中部学院大学・中部学院大学短期大学部研究紀要, Vol. 23, pp. 57–63, 2022.
- [9] 森祐貴, 中山雅斗, 長江晃生. 大学女子バレーボールにおけるディグパフォーマンスに関する一考察 : ディグ対応動作と打球種類に着目して. バレーボール研究, Vol. 23, No. 1, pp. 49–53, 2021.
- [10] Yufan Wang, Yuliang Zhao, Rosa H. M. Chan, and Wen J. Li. Volleyball Skill Assessment Using a Single Wearable Micro Inertial Measurement Unit at Wrist. *IEEE Access*, Vol. 6, pp. 13758–13765, 2018.
- [11] Fasih Haider, Fahim A. Salim, Dees B. W. Postma, Robby van Delden, Dennis Reidsma, Bert-Jan van Beijnum, and Saturnino Luz. A Super-Bagging Method for Volleyball Action Recognition Using Wearable Sensors. *Multimodal Technologies and Interaction*, Vol. 4, No. 2, p. 33, 2020.
- [12] Miki Jauhiainen and Michael D. Jones. Using Machine Learning to Classify Volleyball Jumps. In *Proceedings of the New Trends in HCI and Sports Workshop (NTSPORT '22 at MobileHCI '22)*, Vol. 3267, pp. 1–6, 2022.
- [13] Shota Nako, Hiroyuki Ogata, Taiji Matsui, Itsuki Hamada, and Jun Ohya. A Hierarchical Classification for Automatic Assessment of the Reception Quality Using Videos of Volleyball and Deep Learning. In *Proceedings of the 14th International Conference on Pattern Recognition Applications and Methods (ICPRAM)*, pp. 673–680, 2025.
- [14] Guoqing Jia. Influence of Wearable Biometric Sensors on Performance Indicators of Volleyball Players. *Systems and Soft Computing*, Vol. 7, pp. 1–10, 2025. Article No. 200238.
- [15] Weiyi Xu, Chunzhuo Wang, Meng Shang, Camilla De Bleecker, Maria Torres Vega, Jos Vanrenterghem, and Bart Vanrumste. AI-assisted Automatic Jump Detection and Height Estimation in Volleyball Using a Waist-worn IMU. *arXiv preprint arXiv:2505.05907*, 2025.
- [16] Mai Hyogu, Ayumi Onishi, and Yuki Matsuda. Detecting Rule Violations in Race Walking Using Instep- and Waist-Mounted Wearable Inertial Sensors. In *Companion of the 2026 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '26 Companion*, pp. 1–5, 2026.
- [17] 公益財団法人日本バレーボール協会. JVA 技術統計判定要領 (国内競技会用). 公益財団法人日本バレーボール協会, 2023. http://tohokugakuren.web.fc2.com/2023/2023_4_jvims.pdf, Accessed: 2026-07-23.
- [18] Data Project. Data Volley 4, 2020. <https://www.datavolley.eu/en/product/data-volley-4/>, Accessed: 2026-07-23.