

サッカーのドリブルにおけるフェイント動作の巧さの 画像解析を用いた評価手法

松見涼輔¹ 土田修平¹ 寺田 努¹ 塚本昌彦¹

概要: サッカーのドリブルにおける重要な技術の一つにフェイントがある。フェイント技術を習得するためには、プレーヤ個人による動作確認の練習が必要であるが、動作確認ではフェイント動作の巧さを評価する際、自身の主観的な感覚に頼るしかないという問題点がある。本研究では、プレーヤがフェイント動作を行う映像を OpenPose を用いて解析することで、プレーヤの骨格情報からフェイント動作の巧さを点数化するシステムを提案する。フェイント動作を点数化することでユーザのフェイント動作の巧さを定量的に評価でき、パフォーマンス向上につながると考える。ここでフェイント動作の巧さの評価基準を、被験者にフェイント動作の映像を見ながらプレーヤが左右どちらに移動するかをキーボード入力で予測してもらい、騙された被験者が多いフェイント動作を巧いフェイントと定義した。また提案システムの構築では三つの学習モデルを用いて、100 個のフェイント動作のデータの内、20 個をテストデータ、80 個を学習データとし各学習モデルを 5 分割交差検証で評価した。予測精度の検証を行った結果、最も低い MAE の値は 1.62 であり、Permutation Importance の結果より体の下半身の特徴点が重要であるとわかった。次に、予測精度の向上のためにプレーヤごとに学習モデルを作成し、特徴量を体の下半身の特徴点のみにした場合で、それぞれのプレーヤにおける推定精度の調査と評価を行った。その結果、最も低い MAE の値が 1.41 となり、精度の向上を確認した。

1. はじめに

サッカーにおいてドリブルは試合中に最もよく行われる動作の一つである。プレーヤはドリブルを行うことでボールを保持しながら相手ゴールの方向へ進むことができる [1]。ここで、ドリブルにおける重要な技術の一つにフェイントがある [2]。フェイントとは、見せかけの動きで相手を惑わし欺くことで意表を突き、ゴールやパスにつなげる技術である。ドリブル中にフェイントを用いることで、自分が進みたい方向と逆の方向に敵対する相手の守備の選手を誘導できる。これにより、フェイントを用いない場合に比べて、簡単に相手を抜き去ることができ、人数的に有利な状況を作り出せる。サッカーでは様々な場面でフェイントを使用するため、プレーするポジションに関係なく、すべての選手がフェイント技術を習得する必要がある。

フェイント技術を習得するためには二つのプロセスが必要である [3]。一つ目はプレーヤ個人による動作確認である。動作確認ではまず、手本となるフェイント動作の映像を見ながら動作を理解し、イメージトレーニングを行う。その後、手本通りのフェイント動作の反復練習を行う。二

つ目は対人確認である。試合における相手の守備の選手との 1 対 1 の場面を想定して、フェイント動作を用いて守備の選手を抜き去る練習を行う。これら二つのプロセスを経ることでフェイント技術を習得できる。本研究ではまずプレーヤ個人による動作確認について着目する。

動作確認ではフェイント動作の巧さを評価する際、自身の主観的な感覚に頼るしかないという問題点がある。新しい技術を習得するためには、その技術を定量的に評価できることが望ましい。実際に、Wulf ら [4, 5] は自身の運動パフォーマンスや運動量に関するフィードバックが、練習の効率や試合におけるパフォーマンスの向上に繋がると述べている。また、サッカーの技術における定量的な評価に関する研究として、金子ら [6] は撮影されたシュート動作の動画を OpenPose を用いて画像解析することで、シュート動作を定量的に評価できることを確認している。このようなサッカーの技術を定量的に評価する研究は数多くあるが、フェイント動作の巧さを評価する方法は筆者の知る限りない。これは、巧いフェイント動作に必要な要素が明確に定まっていないことが原因であると考えられる。

そこで本研究では、プレーヤがフェイント動作を行う映像を OpenPose を用いて解析することで、プレーヤの骨格情報からフェイント動作の巧さを点数化するシステムを

¹ 神戸大学大学院工学研究科
Graduate School of Engineering, Kobe University

提案する。プレーヤーは前方に設置されているコーンマーカを守備の選手とみなしてフェイント動作を行い、左右のどちらかの方向にドリブルを行う。この一連のフェイント動作をプレーヤーの正面から撮影した映像からフェイント動作のパラメータを抽出する。ここでのパラメータとは、関節の角度や動作の緩急であり、フェイントの巧さに関係する要素である。パラメータを抽出するために OpenPose を使用する。OpenPose は、人物の骨格を深層学習 (Deep Learning) で推定するシステムで [7]、画像や動画から三次元的に身体の動きを検出できる。提案システムでは機械学習を用いてフェイント動作の点数化を行うモデルを作成する。まず、行われたフェイント動作の映像から OpenPose を用いて各関節データを取得し、特徴量を選定する。次に、フェイント動作に騙されたかどうかを定量的に評価し、騙された被験者の人数を正解ラベル付きデータとする。作成したモデルを用いた提案システムでフェイント動作を点数化することで、ユーザのフェイント動作の巧さを定量的に評価できると考える。なお、サッカーにおけるフェイント動作の種類は多数存在するが、本研究ではサッカーの試合中によく使用される、シザースというフェイント動作を対象として点数化を行った。

2. 関連研究

スポーツにおいて OpenPose を用いた画像解析による姿勢推定の活用については、いくつかの研究がある [10, 11]。まず、これらの研究の概要を述べ、我々の研究との関連を議論する。次にサッカーにおける定量的なパフォーマンス分析について議論し、先行研究 [14, 15] をレビューすることで、先行研究の課題について述べる。最後に、スポーツと欺瞞的行動に関する先行研究の例を紹介し [16–19]、欺瞞的行動が相手に及ぼす影響について述べる。以上の議論を踏まえて、フェイント動作の巧さを定量的に評価するシステムを提案する。

2.1 スポーツにおける OpenPose の活用

OpenPose を用いた画像解析による人間の姿勢推定を活用した研究は、スポーツや医学の分野において数多く行われている。Suda ら [10] は 2 名のバレーボールのプレーヤーのトスについての実験で、実際のトスが行われる 0.3 秒前にバレーボール軌道の予測を行った。予測を行う際、Kinect を用いて取得した身体関節の三次元データを簡易ニューラルネットワークに入力し、OpenPose を用いて推定した二次元データを比較対象として用いた。提案手法によりバレーボールのトス軌道が適切に予測され、トス軌道の誤差はボールの大きさと同程度等しいことが確認された。また、トス予測に寄与する重要な身体部位を特定できることも示しており、バレーボールのプロのアナリストはこの技術が相手選手のトスの癖の分析にも使用可能であると述べ

ている。Park ら [11] は韓国陸軍の規則を考慮した正しい腕立て伏せと間違った腕立て伏せの識別を行うことで、2 次元ビデオ画像を用いて正しい腕立て伏せのみをカウントするリアルタイムアプローチシステムを提案した。提案手法は、撮影された腕立て伏せの映像の各フレームにおいて、OpenPose を用いて人体の複数の関節を抽出し、腕立て伏せのカウントに関連する主要な動作特徴を分析する。計 220 本の腕立て伏せ動画から 147,840 個のサンプルを収集し、結果を比較した。その結果、カウント精度は 90.0% を示し、本システムを軍事体力テストに導入できることの信頼性が実証された。このように OpenPose を用いて画像解析することで、スポーツにおける姿勢推定を手軽に高精度で行うことができる。本研究ではフェイント動作の映像を OpenPose で画像解析することで、選手の骨格情報からフェイント動作の巧さを評価できるのではないかと考える。

2.2 定量的な評価を用いたサッカーのパフォーマンス分析

サッカーのパフォーマンスにおいて、熟練した動作パターンを効率的かつ効果的に実行する能力は最も重要であり、プレーヤーは急速に変化する状況に対して認知、知覚、運動など、様々な能力を適用しなければならない [12]。このような能力を評価する際には、数値を用いて定量的に評価するのが望ましい。例えば、ドリブル技術を測定する際に用いられる数値としてスキルインデックスがある [13]。スキルインデックスとは、やや複雑な非直線のコースを完走するのにかかる時間であるスプリントタイムを、同コースをドリブルしながら走行するのにかかる時間であるドリブルタイムで割った数値である。Mirkov ら [14] は 20 歳前後の男性サッカー選手 20 名を対象にスキルインデックスの検証実験を行い、この数値がドリブル能力の評価に利用できることを示唆している。Williams ら [15] は大学サッカー部の熟練者 24 名と非熟練者 24 名を対象に、サッカー技術評価ツールとして LSPT (Loughborough Soccer Passing Test) 及び LSST (Loughborough Soccer Shooting Test) を行わせた。LSPT は、16 本のパスをできるだけ早く完了することが要求される。LSST では、フルサイズのゴールのターゲットにボールをパスし、コントロールし、シュートすることが要求される。その結果、LSPT と LSST はサッカー技術のパフォーマンスの違いを評価するための有効かつ信頼性の高いツールであることが確認された。

しかし、以上の研究では技術を用いたパフォーマンスの「結果」を定量的に評価しており、その過程にあたる技術の「動作」自体の定量的な評価は行っていない。例えば、スキルインデックスではドリブルで完走する時間の早さ評価しており、ドリブルの動作 (姿勢やリズム感など) は評価していない。技術を習得するためには、まず技術の「動作」を適切に行えることが前提である。本研究では、フェイントの「動作」の巧さを定量的に評価する必要があると考え、

評価に必要な指標を新しく設定する。

2.3 スポーツと欺瞞的行動の関連性

スポーツ分野で相手を意図的に欺く行為（フェイント）に関する研究が行われている。Jackson ら [16] は、熟練ラグビー選手 14 名と初心者ラグビー選手 14 名を対象に、欺瞞的動作を検出する能力を調査した。被験者は、熟練ラグビー選手と初心者ラグビー選手が欺瞞的行動を行いながら方向を変える映像と欺瞞的行動を行わない映像に対して、選手が転換する進行方向を予測し、判断の確信度を記録した。その結果、熟練者と初心者の両方が欺瞞的行動を行わない試行で、より方向の予測に自信をもつことがわかった。Schmidt ら [17] は運動能力と知覚感覚が欺瞞的行動と非欺瞞的行動の区別に及ぼす影響を検討した。また、欺瞞的動作と非欺瞞的動作の知覚判断の違いは、必ずしも運動能力や知覚感覚の違いによって生じる必要はなく、反応バイアスの結果である可能性があるという仮説を検証した。ハンドボール熟練者 50 名と初心者 50 名は、7m スローのシュートとフェイクのどちらの動作を行ったか予測を行った。信号検出理論（SDT：Signal Detection Theory）分析の結果、熟練ハンドボール選手はシュートとフェイクの識別において初心者よりも優れていた。また、ゴールキーパーとフィールドプレーヤーとの間に知覚感覚の差はみられなかった。しかし、ゴールキーパーは動きを偽物と判断するバイアスが有意に大きく、フィールドプレーヤーと初心者はこのような反応バイアスを示さなかった。Weigelt ら [18] はバスケットボールのヘッドフェイク効果から、スポーツにおける欺瞞的行為の認知メカニズムを調査した。選手がボールをパスしながらパスの方向と逆側を見る場合、選手がパスの方向を見る場合よりも相手選手の反応は遅くなる。このヘッドフェイク効果が、行為と無関係な視線方向の処理に基づくのか、頭の向きに基づくのか、あるいはその両方に基づくのかを調査した。その結果、選手の目を隠してもヘッドフェイク効果が減少しないことが判明し、視線方向と頭の向きの相対的な影響を分離できた。よって、バスケットボールにおけるヘッドフェイク効果は視線情報ではなく、頭の向きに基づくことが示唆された。Weigelt ら [19] はスポーツ分野における欺瞞的行動に関する研究は、時代や科学分野を超えて散見されると述べており、インタラクティブスポーツにおける欺瞞的行動に関する実証的研究を系統的にレビューし、過去数十年間に行われた研究の二つの問題点について概観した。(1) 欺瞞的行為の認識における専門知識の役割、(2) 欺瞞的行為の処理の基礎となる認知メカニズムである。これらのテーマは、今後の研究課題として検討する必要があると述べている。このように、欺瞞的行動に対する守備側の選手の予測や反応についての研究は多く行われている。そのため、フェイント動作に対する守備側の予測を調査することで、フェイント



図 1 システム作成の手順

動作によってどの程度相手を欺けたかを判定できると考える。また本研究では、サッカーのドリブルにおいて欺瞞的行動にあたるフェイント動作を解析することで、フェイント動作を定量的に評価するための指標に必要な要素を解明する。

3. 提案システム

3.1 フェイント動作の巧さの定義

フェイント動作の巧さを評価するためには、対象とするフェイント動作の巧さを定量的に判定するための基準を定義する必要がある。Iris ら [8] は、フェイントは「欺瞞的な行動をとること」と定義している。また、サッカー熟練者は初心者に比べてフェイント動作に騙されにくいことが確認されている [9]。そのため、フェイント動作の巧さの評価を、相手の守備の選手を騙せたかどうか（抜く方向を相手に予測されなかったかどうか）で判定することで、フェイント動作の定量的評価が可能であると考えられる。以上よりフェイント動作の巧さの評価基準を、被験者にフェイント動作の映像を見ながらプレーヤーが左右どちらに移動するかをキーボード入力で予測してもらい、騙された被験者が多いフェイント動作を巧いフェイントと定義した。

3.2 推定手法

本研究では、OpenPose を用いた画像解析によりフェイント動作の巧さの点数化を行うシステムを作成する。システム作成の手順を図 1 に、手順の詳細を以下に示す。

手順 1 フェイント動作の撮影をする。

手順 2 手順 1 で撮影した映像から OpenPose を用いてプレーヤーの骨格情報を取得し、機械学習における特徴量を算出する。また、取得したプレーヤーの骨格情報データの前処理として、フェイント動作の映像から動作部分の切り出しを行う。

手順 3 手順 1 で撮影したフェイント動作の映像を見て移動方向をキーボード入力で予測する手法を用いて、フェイント動作に騙されたかどうかの判定を行い、正解ラベル付きデータを作成する。

手順 4 手順 2, 3 で作成した正解ラベル付きデータを用いて機械学習を行い、フェイント動作の巧さの点数化を

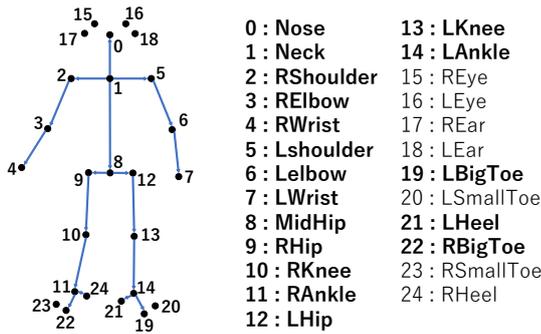


図 2 OpenPose から得られる 25 の特徴点

行うモデルを作成する。

3.3 特徴量

3.3.1 OpenPose によるデータ収集

先述した手順 1 のように、OpenPose を用いて撮影したフェイント動作の映像を解析する。OpenPose とは、映像中の人物に対して図 2 のような 25 の特徴点 (二次元 x, y 座標) を推定し、骨格情報として抽出できるシステムである。また、それぞれの特徴点に対して信頼度 (0 ~ 1 の間の数値) が存在する。OpenPose は隠れた位置の部位まで推測するため、信頼度が低いと正確な値とは言えない。今回は特徴点を抽出する際は信頼度が 0.1 以上になるように設定した。ここで、カメラに対してフェイント動作を行う位置が毎回変化しているため、単純に特徴点の座標を比較できないという問題点がある。そのため、取得した 25 の特徴点を単位ベクトルに変換することによって基準を統一し、解析を行った。単位ベクトルに変換する部分は、座標の隣り合った 2 点を結んだ部分である。例えば、図 2 において右股関節 (点 9) から右膝 (点 10) を結んだ線である。式 1 に点 A から点 B を結んだ線を単位ベクトルに変換するための算出式を示す。A, B にはそれぞれ隣り合う骨格座標が入る。A, B の x, y 座標をそれぞれ A_x, A_y, B_x, B_y とする。

$$\frac{\vec{AB}}{|AB|} = \frac{(B_x, B_y) - (A_x, A_y)}{\sqrt{(B_x - A_x)^2 + (B_y - A_y)^2}} \quad (1)$$

単位ベクトルに変換後、単位ベクトルの x, y 成分の動画フレーム間の変化量を単位ベクトルの速度とし、速度の動画フレーム間の変化量を単位ベクトルの加速度として算出した。

次に手順 2 として、撮影された映像からフェイント動作の部分のデータを抽出するために、図 3 のように映像からフェイント動作が行われた部分を取り出した。著者が目視にて、フェイント動作を行い左右に移動したタイミングをラベル付けし、ラベル付けたタイミングから 25 フレーム (約 0.8 秒) 前をフェイント動作開始位置とし、ラベル付けたタイミングから 5 フレーム (約 0.2 秒) 後をフェイン

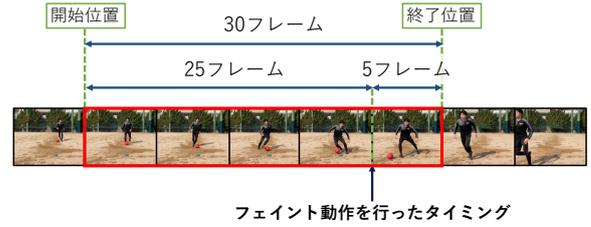


図 3 フェイント動作の映像の切り出し

ト動作終了位置とする。切り出した動画の長さでは 30 フレーム (約 1 秒) である。

3.3.2 特徴量の選定

本研究では、図 2 に示す特徴点の組み合わせとして、 $(A, B) = (1, 0), (1, 2), (1, 5), (1, 8), (2, 3), (3, 4), (5, 6), (6, 7), (8, 9), (9, 10), (10, 11), (11, 22), (11, 24), (8, 12), (12, 13), (13, 14), (14, 19), (14, 21)$ の全部で 18 箇所の単位ベクトルを算出した。OpenPose から得られたプレーヤの 10 箇所の関節間の単位ベクトルにおける、 x, y 軸それぞれの方向で a~g の組み合わせで特徴量を用いた。

- (a) 単位ベクトルの成分, 速度, 加速度の平均値と分散値
- (b) 単位ベクトルの成分, 速度の平均値と分散値
- (c) 単位ベクトルの成分, 加速度の平均値と分散値
- (d) 単位ベクトルの速度, 加速度の平均値と分散値
- (e) 単位ベクトルの成分の平均値と分散値
- (f) 単位ベクトルの速度の平均値と分散値
- (g) 単位ベクトルの加速度の平均値と分散値

3.4 正解ラベル付きデータの作成

システム作成における機械学習には、フェイント動作の巧さを定量的に評価した正解ラベル付きデータが必要である。Wright ら [20] は相手側のサッカー選手が視聴者に向かってドリブルする映像が連続で流れるビデオ (全部で 100 本の映像が流れ、そのうち半分がフェイント動作、半分がフェイント動作を行わないドリブル動作) を見て、選手が左右どちらの方向に移動するかの予測をキーボード応答によって記録した。フェイント動作が映し出される映像を見て左右どちらの方向に移動するかを予測することで、フェイント動作に騙されたかどうかを判定できるのではないかと考えた。本研究では、被験者にフェイント動作の映像を見ながらプレーヤが左右どちらに移動するかをキーボード入力で予測してもらい、騙された被験者が多いフェイント動作を巧いフェイントと定義する。行われたフェイント動作が相手プレーヤを騙しているかを定量的に評価することで、正解ラベル付きデータの作成を行う。

3.4.1 正解ラベルの付与

正解ラベル付与の様子を図 4 に示す。机上に PC を設置し、異なるフェイント動作が連続で流れる映像を映し出す。PC に映し出されるフェイント動作の映像を図 5 に示す。一回のフェイント動作の映像は約 3 秒で、合計 164 回



図 4 キーボード入力による予測の様子



図 5 PC に映し出される映像

映像が流れる。被験者は映像を視聴しながら、映し出されるそれぞれのフェイント動作に対して、左右どちらの方向に移動するかを予想し、被験者から見て右方向へ移動したと予想したときは d を、左方向へ移動したと予想したときは a を入力する。被験者がキーボード入力を行うタイミングは、フェイント動作を行った選手が左右に移動すると感じた瞬間であり、入力は一回のフェイント動作につき一度のみである。2名のサッカー経験者がフェイント動作を行う様子をカメラで撮影し、その映像を提示した。最終的に進む方向(左右)の回数はフェイントの種類ごとに同じとした。また、同じ種類のフェイント動作の視聴による予測の慣れをなくすために、複数の種類のフェイント動作を用いた。映し出されるフェイント動作の種類と回数を表1に示す。実験の対象となるフェイントはシザースのみで、それ以外のフェイントはフェイクの動作とし、映像はシザースとフェイクの動作がランダムに映し出される。

フェイント動作の撮影を行っている様子を図6に示す。プレーヤーはドリブル開始位置から11m離れた位置にあるコーンマーカに向かって直線的にドリブルし、コーンマーカの直前でフェイント動作を行い左右どちらかの方向にドリブルする。この一連の動作を選手の前方向にあるカメラで撮影する。撮影にはApple社のiPadAir4のカメラを使用した。

被験者は、20代男女の12名(サッカー経験者5名、未経験者7名)で行った。流れる映像の順序による影響をなくすために、映し出されるフェイント動画の流れる順序は全部で6パターン用意し、各パターン2名ずつの被験者を割

表 1 PC に映し出されるフェイント動作の種類と回数(1人当たり)

フェイント名	回数
シザース	50回
ダブルシザース	10回
トリプルシザース	2回
ボディーフェイント	20回

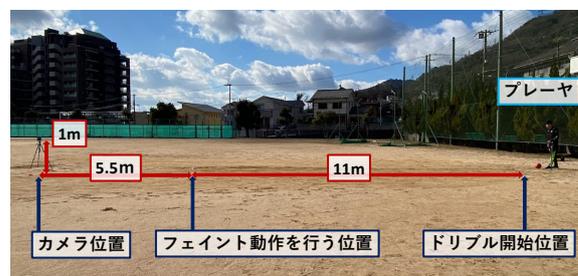


図 6 フェイント動作撮影の様子

り当てた。フェイント動作の映像で使用したサッカーボールはMIKASA社のF5TPであり、使用したPCはLenovo社のThinkPad x395(13-inch, 2018)である。また正解ラベルの付与後に、映像で流れたフェイント動作の移動方向の予測の難易度、及びフェイント動作に対して体のどの部分を見ていたかについてのアンケート調査を行った。

3.4.2 判定基準

被験者がフェイント動作に騙されたかを適切に判定するために、判定基準の設定を行う。Henryら[21]は、オーストラリアンフットボールにおけるフェイント動作に対する反応性、及び敏捷性テストを行い、フェイント動作の反応速度は非フェイント動作の反応速度より遅くなることを確認している。この結果より、フェイント動作への反応速度をフェイント動作に騙されたかの判断に考慮する必要があると考えられる。本研究では、各フェイント動作が映し出される映像において、選手がフェイント動作を行い、左右に移動したタイミングを筆者が目視で判断しラベル付けした。ラベル付けしたタイミングを「フェイント動作が行われたタイミング」と設定し、以下の基準のどちらか一方でも満たしたときフェイント動作に騙されたと判断する。

- 予測した方向がフェイント動作の移動方向と異なるとき
- 予測したタイミングとフェイント動作が行われたタイミングに10フレーム(約0.3秒)以上の差があるとき

図7に各フェイント動作に騙されたかどうかの判定基準をグラフで示す。グラフの横軸は映像のフレームを、縦軸は被験者が予測した方向を表しており、右方向に予測した場合は -1 、左方向に予測した場合は 1 を出力する。図7(a)は予測した方向とフェイント動作の移動方向が異なるので騙されたと判定する。図7(b)は予測したタイミングとフェイント動作が行われたタイミングに10フレーム以

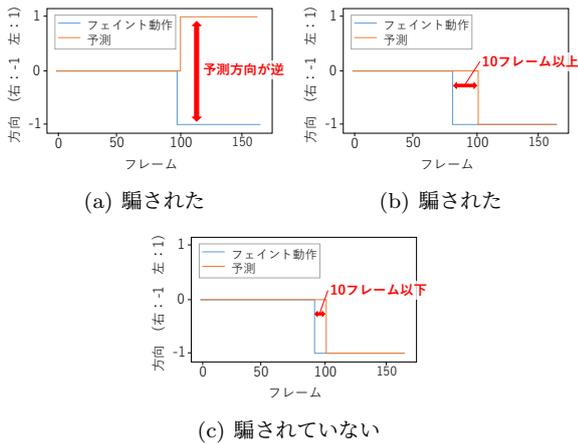


図 7 フェイント動作に騙されたかどうかの判定基準

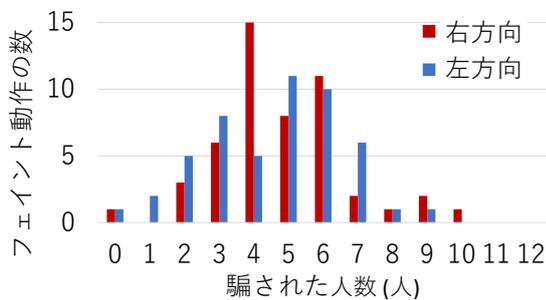


図 8 フェイント動作撮影の様子

上の差があるため騙されたと判定する。図 7(c) は予測した方向とフェイント動作の移動方向が一致し、かつ予測したタイミングとフェイント動作が行われたタイミングの差が 10 フレーム以内なので騙されていないと判定する。なお、閾値は実験的に決定した。

3.4.3 データ内訳

騙された人数に対するフェイント動作の数を図 8 に示す。騙された人数が最も多かったフェイントは 10 人を騙すことができ、誰も騙されていないフェイントも確認できる。騙された人数に対するフェイント動作の数にばらつきが生じたため、巧いフェイント (相手を騙せるフェイント) とそうでないフェイントを区別可能だと判断できる。この結果より、それぞれのフェイント動作に対して「騙された人数」を機械学習の正解ラベル付きデータとし、フェイント動作の巧さを定量的に評価する。

フェイント動作の映像視聴後に行ったアンケート調査では、12 人中 11 人の被験者がフェイント動作抜く方向の予測は難しいと感じたと回答した。また、予測の際にフェイント動作を行ったプレーヤのどの部分を見ていたかについてのアンケート調査の結果、多くの被験者がプレーヤの下半身、特に体の股関節、膝、足首の位置を見ていたと答えた。この結果より、フェイント動作に騙されたかどうか、プレーヤの股関節、膝、足首の動きが関係しているのでは

ないかと考えられる。

4. 実験 1

3 章で作成した提案システムを用いて、フェイント動作の巧さの点数を推定し、推定精度の調査と評価を行った。なお本実験は、神戸大学大学院工学研究科人を直接の対象とする研究倫理審査委員会の承認を受けて行ったものである。

4.1 実験内容

4.1.1 学習モデル

本実験では、3 章で述べた手順によって取得した 100 個のフェイント動作のデータの内、20 個をテストデータ、80 個を学習データとし各学習モデルを 5 分割交差検証で評価した。機械学習に用いる特徴量は、OpenPose から算出した 18 箇所の関節間の単位ベクトルにおける、 x, y 軸方向の成分、速度、加速度の平均値、分散値である。使用する学習モデルは、ニューラルネットワーク [22]、ランダムフォレスト [23]、SVR (Support Vector Regression) [24] で、この三つの学習モデルを用いて回帰分析を行うことで、フェイント動作の巧さの点数を推定した。フェイント動作の巧さの点数は、3.3 節に記載した「フェイント動作に騙された回数」である。最後に、学習データに対する推定誤差を折れ線グラフで可視化した。

4.1.2 精度評価指標

回帰分析は、入力 x に対し出力 y が数値データとして得られる分析方法である。回帰分析の精度を評価する際に、テストデータの実測値 $y_i (i = 1, 2, 3, \dots, n)$ を出力の予測値 \hat{y} がどの程度再現できているかを検討する必要がある。本研究では、回帰分析の推定精度の評価関数に MAE を用いる。MAE は式 2 で表され、実測値と予測値が近づくほど、MAE は小さくなる。MAE は誤差を二乗していないため、外れ値の影響を受けにくい。機械学習の推定精度は、学習モデルごとに MAE の結果を比較することで評価を行った。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}| \quad (2)$$

4.1.3 特徴量の重要度評価

機械学習における特徴量の選定には、どの特徴量がモデルの予測精度向上にどれだけ寄与しているかを把握する必要があるため、Permutation Importance [25] を用いる。Permutation Importance では、学習における特徴量を並び替えたあとのモデルの予測誤差の影響を算出することで、特徴量の重要度を算出する。特徴量の値を入れ替えてモデル誤差が増加する場合、モデルは特徴量に依存した予測をしているので、その特徴量は「重要」となる。また、特徴量の値を入れ替えてもモデル誤差が変わらない場合、特徴量は「重要ではない」といえる。学習済みモデルを f 、特徴量

表 2 特徴量の組み合わせごとの推定誤差

学習モデル	a	b	c	d	e	f	g
SVR	1.76	1.76	1.76	1.77	1.73	1.77	1.77
ニューラルネットワーク	2.34	2.17	2.26	2.09	2.18	2.07	2.08
ランダムフォレスト	1.64	1.64	1.65	1.65	1.62	1.63	1.63

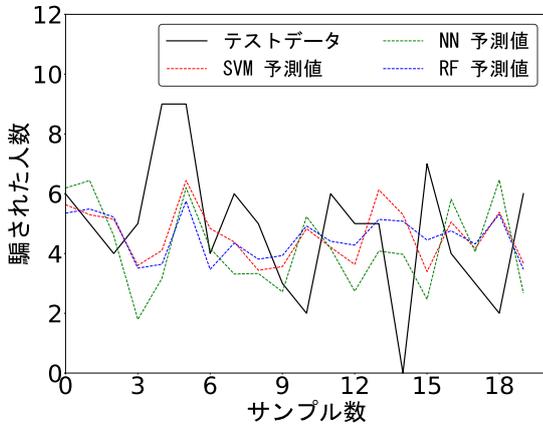


図 9 特徴量：e

行列を X ，ターゲットベクトルを \mathbf{y} ，損失関数 (MSE) を $L(\mathbf{y}, f)$ としたときの，Permutation Importance (PI) の算出手順を以下に示す。

- (1) 学習モデルを用いて誤差 $e^{orig} = L(\mathbf{y}, f(X))$ を計算
- (2) 全ての特徴量 $j = 1, 2, 3, \dots, J$ に対して
 - (a) データ X の特徴量 j を並べ替えて特徴量行列 X^{perm} を生成
 - (b) 並べ替えられたデータの予測値に基づいて，誤差 $e^p = L(\mathbf{y}, f(X^{perm}))$ を推定
 - (c) 並べ替えた特徴量の重要度 $PI^j = e^{perm} / e^{orig}$ を算出

Permutation Importance の値を比較することで，フェイント動作の巧さに重要な特徴量を解析する。

4.2 実験結果

各特徴量の組み合わせにおける MAE の値を表 2 に示す。フェイント動作の巧さの予測値の結果の内，最も MAE の値が低かったときの予測値の結果を図 9 に示す。表 2 より学習モデルごとに比較すると，ランダムフォレストが MAE の値の結果が低く，ニューラルネットワークが最も高かった。特徴量の組み合わせごとに比較すると，ニューラルネットワークの結果は特徴量の組み合わせが d, f, g の場合が MAE の値の結果がともに低く，SVR とランダムフォレストは特徴量の組み合わせによる MAE の結果にあまり差がなかった。最後にすべての学習モデルと特徴量の組み合わせで比較すると，最も MAE が低かったのは，特徴量の組み合わせが e で学習モデルがランダムフォレストの場合であり，値が 1.62 だった。また，図 9 の結果より，すべての特徴量の組み合わせで外れ値が多く，グラフの誤差が大きかった。図 10 に特徴量の組み合わせが単位ベク

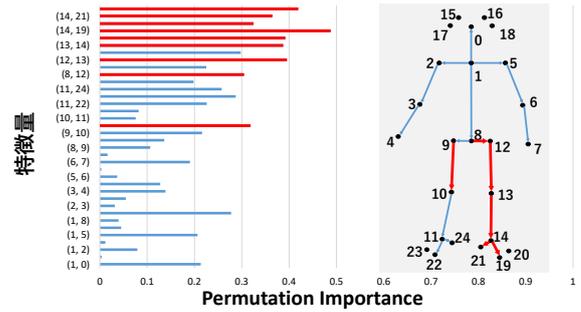


図 10 特徴量の重要度

表 3 特徴量の組み合わせごとの推定誤差

学習モデル	プレーヤ	a	b	c	d	e	f	g
SVR	A	1.51	1.50	1.50	1.48	1.48	1.48	1.47
	B	2.02	2.02	2.02	2.03	2.06	2.03	2.03
ニューラルネットワーク	A	2.02	2.20	2.14	1.92	1.84	1.81	1.97
	B	2.56	2.79	2.53	2.60	2.59	2.36	2.54
ランダムフォレスト	A	1.42	1.49	1.41	1.43	1.47	1.44	1.50
	B	1.86	1.88	1.87	1.96	1.84	1.92	2.00

トルの成分のみで学習モデルがランダムフォレストの場合の Permutation Importance の結果を示す。この結果より，体の下半身の部位が特徴量として重要であるとわかる。

5. 実験 2

4 章の結果を踏まえて，予測精度の向上のためにプレーヤごとに学習モデルを作成し，それぞれのプレーにおける推定精度の調査と評価を行った。また，Permutation Importance の結果より，特徴量を体の下半身の特徴点のみにした。

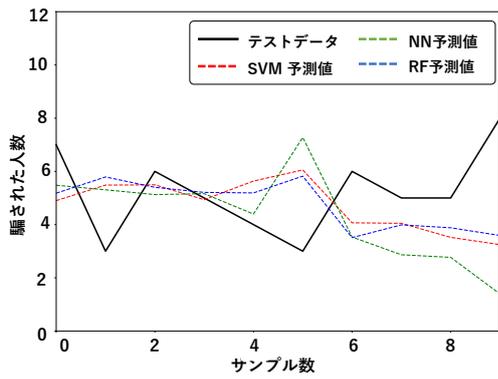
5.1 実験内容

5.1.1 学習モデル

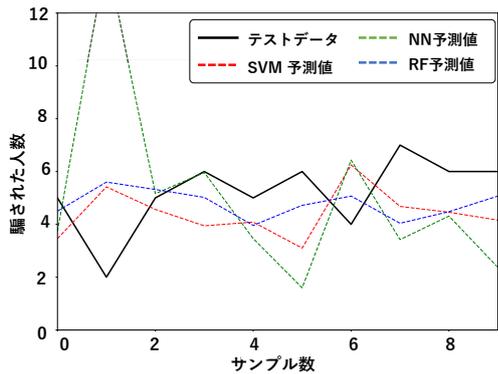
本実験では，3 章で述べた手順によって取得した 100 個のフェイント動作のデータをプレーヤごとに 50 個ずつに分け，10 個をテストデータ，40 個を学習データとし各学習モデルを 5 分割交差検証でプレーヤごとに評価した。機械学習に用いる特徴量は，OpenPose から算出した 18 箇所の関節間の特徴点のうち下半身の (A, B) = (8, 9), (9, 10), (10, 11), (11, 22), (11, 24), (8, 12), (12, 13), (13, 14), (14, 19), (14, 21) の全部で 10 箇所の特徴点を用いた。使用する学習モデルは，実験 1 と同様にニューラルネットワーク，ランダムフォレスト，SVR で，この三つの学習モデルを用いて回帰分析を行うことで，プレーヤごとのフェイント動作の巧さの点数を推定した。

5.2 実験結果

各特徴量の組み合わせにおける，プレーヤごとの MAE の値を表 3 に示す。フェイント動作の巧さの予測値の結果の内，最も MAE の値が低かったときの各プレーヤの予測値の結果を図 11 に示す。表 3 の結果より，学習モデルご



(a) プレーヤ A 特徴量 : c



(b) プレーヤ B 特徴量 : e

図 11 フェイント動作に騙されたかどうかの予測結果

とに比較すると、ランダムフォレストが MAE の値が低く、ニューラルネットワークが最も高かった。また、特徴量の組み合わせごとに比較すると、ニューラルネットワークの結果は特徴量の組み合わせが単位ベクトルの速度のみの場合が MAE の値が比較的低く、SVR とランダムフォレストは特徴量の組み合わせによる MAE の値にあまり差がなかった。プレーヤごとに比較するとプレーヤ A の MAE の値がプレーヤ B の MAE の値よりも約 0.5 低い結果となった。最後に、最も MAE の値が低かったのがプレーヤ A の特徴量の組み合わせが単位ベクトルの成分と加速度で学習モデルがランダムフォレストの場合で、値が 1.41 であり実験 1 の結果と比較すると精度が少し高い結果となった。しかし、図 11 より、グラフの誤差が大きいことから精度が高い結果とはいえない。

6. 考察

本章では正解ラベル作成の結果と機械学習の評価実験の結果を踏まえて、提案システムの改善点についての議論を行う。

6.1 正解ラベル付きデータの作成

本研究ではフェイント動作の巧さの評価基準を、被験者にフェイント動作の映像を見ながらプレーヤが左右どちら

に移動するかをキーボード入力で予測してもらい、騙された被験者が多いフェイント動作を、巧いフェイントと定義した。しかし、作成した正解ラベルは先行研究 [9] の「熟練者は初心者よりフェイント動作に騙されにくい」という結果と一致しなかった。これは、予測方向は左右の二択のため、予測ができなくても偶然予測方向が当たることが十分起こり得るということや、映像の視聴での予測は実際にプレーヤと対峙して行う予測と大きく状況異なることが原因だと考える。以上より、本研究で用いたキーボード入力による判定は、フェイント動作に騙されたかどうかの判定に適していないといえる。

6.2 フェイント動作の解析手法

本研究では OpenPose を用いて画像解析を行ったが、OpenPose は二次元の骨格情報しか得ることができない。しかし、実際のフェイント動作には体の前後の動きも含まれるため、三次元的に動作解析を行う必要がある。また OpenPose による解析は、映像を動作の正面方向から撮影する必要があり、守備の選手と対峙した状況では撮影を行えない。そこで、Kinect やモーションキャプチャなどのシステムを使用すれば、三次元で人物の骨格情報を取得でき、守備の選手がいる状況でも動作を解析できると考える。今後は、三次元で解析を行える Kinect やモーションキャプチャを用いて、フェイント動作の解析を行う。

また、本研究では機械学習の特徴量として、各関節間の単位ベクトルの成分、速度、加速度を選定した。しかし、フェイント動作の巧さの要素にはプレーヤの重心位置やボールの位置なども影響すると予想されるため、これらの要素を考慮した特徴量の再考が必要であると考えられる。

6.3 機械学習の予測精度

本研究では三つの学習モデルを用いて機械学習を行い、評価関数を用いてフェイント動作の巧さの予測精度を評価した。予測結果より、すべての特徴量の組み合わせで外れ値が多く MAE の値が高かった。ランダムフォレストと SVM はニューラルネットワークと比べて MAE の結果が低かったが、実際に図 11 のグラフを確認すると、騙された人数の予測が 4~6 人の値に集まっており、この値はフェイント動作に騙された人数の中央の値である。MAE は予測の誤差の平均を取っているため、中央の値域を取るランダムフォレストと SVM の MAE 値が小さいと考えられ、機械学習の精度が高いとは言えない。これは、モデル作成におけるデータの数全部で 100 個と少ないことと、重要な特徴量を選定できてないためだと考える。また、プレーヤ A とプレーヤ B の結果に差が生じたことから、プレーヤの癖によってフェイント動作の巧さに個人差が生じると予測される。

7. まとめ

本研究では、プレーヤがフェイント動作を行う映像を OpenPose を用いて解析することで、プレーヤの骨格情報からフェイント動作の巧さを点数化するシステムを提案した。なお、フェイント動作の巧さの評価基準を、被験者にフェイント動作の映像を見ながらプレーヤが左右どちらに移動するかをキーボード入力で予測してもらい、騙された被験者が多いフェイント動作を巧いフェイントと定義した。提案システムの作成における機械学習の正解ラベル付きデータをフェイント動作に騙された人数とし、特徴量は OpenPose で得たプレーヤの関節間の単位ベクトルの成分、速度、加速度とした。次に、作成した正解ラベル付きデータを用いて各学習モデルを 5 分割交差検証により機械学習を行った。しかし、作成した正解ラベルは先行研究の「熟練者は初心者よりフェイント動作に騙されにくい」の結果と一致しなかったため、フェイント動作の巧さの再定義、及び正解ラベル付きデータ作成の手法を再検討する必要があると考えられる。また、三つの学習モデルを用いて機械学習の精度の検証を行った結果、全てのモデル及び特徴量の組み合わせで MAE の値が高かったため、精度が低い結果といえる。

今後はフェイント動作の巧さを「相手の守備の選手を抜ける」ことと再定義し、実際に守備の選手と対峙した状況でフェイント動作を行い相手を抜き去ることができれば、行われたフェイント動作は巧いと評価する。また、本研究では OpenPose を用いて二次元で画像解析を行ったが、厳密にはフェイント動作は三次元の動きである。そのため、Kinect やモーションキャプチャなどの三次元で人物の骨格情報を取得できるシステムを使用して、守備の選手と対峙し、フェイント動作を用いて相手を抜く状況での動作の解析を行う。これにより、試合で実際にフェイント動作を使用することを考慮したフェイント動作の解析が可能になる。さらに、本研究では特徴量として、時系列データの平均値と分散を算出して用いた。しかし、フェイント動作の巧さにリズムや緩急が必要であると予想されるため、LSTM (Long Short-Term Memory) などの時系列データの特徴量として用いる学習モデルを使用する。以上より、データの数を増やし、再考した特徴量と学習モデルを用いて提案システムを作成する。また、提案システムを実際に被験者に使用してもらい、評価実験を行うことでシステムの有効性を評価し、フェイント動作の効率的な習得方法の確立を目指す。

謝辞

本研究の一部は、JST CREST(JPMJCR18A3) の支援によるものである。ここに記して謝意を表す。

参考文献

- [1] A. P. Cabo, E. Rey, A. Kalen, and P. B. Costa: Effects of Training with an Agility Ladder on Sprint, Agility, and Dribbling Performance in Youth Soccer Players, *Journal of Human Kinetics*, Vol. 73, No. 1, pp. 219–228 (July 2020).
- [2] K. Aggerholm, E. Jespersen, and L.T. Ronglan: Falling for the Feint - An Existential Investigation of a Creative Performance in High-Level Football, *Journal of Sport Ethics and Philosophy*, Vol. 5, No. 3, pp. 343–358 (Oct. 2011).
- [3] 増田 稜, 山本景子, 倉本 到, 辻野嘉宏: 仮想ディフェンダーシミュレータによるサッカーのフェイント個人練習システム, 研究報告ヒューマンコンピュータインタラクション (HCI), pp. 1–8 (Mar. 2018).
- [4] G. Wulf, N. McConnel, M. Gartner, and A. Schwarz: Enhancing the Learning of Sport Skills through External-Focus Feedback, *Journal of Motor Behavior*, Vol. 34, No. 2, pp. 171–182 (Apr. 2010).
- [5] G. Wulf, C. Shea, and R. Lewthwaite: Motor Skill Learning and Performance: A Review of Influential Factors, *Journal of Medical Education*, Vol. 44, No. 1, pp. 75–84 (Jan. 2010).
- [6] 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, Vol. JSAI2020, p. 3M5GS1205 (June 2020).
- [7] Z. Cao, T. Simon, S. E. Wei, and Y. Sheikh: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields, *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 7291–7299 (July 2017).
- [8] I. Guldenpenning, W. Kunde, and M. Weigelt: How to Trick Your Opponent: A Review Article on Deceptive Actions in Interactive Sports, *Journal of Frontiers in Pharmacology*, Vol. 8, No. 917, pp. 1–12 (May 2017).
- [9] G. J. Henry, B. Dawson, B. S. Lay, and W. B. Young: Decision-Making Accuracy in Reactive Agility: Quantifying the Cost of Poor Decisions, *Journal of Strength and Conditioning Research*, Vol. 27, No. 11, pp. 3190–3196 (Nov. 2013).
- [10] S. Suda, Y. Makino, and H. Shinoda: Prediction of Volleyball Trajectory using Skeletal Motions of Setter Player, *Proc. of the 10th Augmented Human International Conference (AH '19)*, No. 16, pp. 1–8 (Mar. 2019).
- [11] H. J. Park, J. W. Baek, and J. H. Kim: Imagery Based Parametric Classification of Correct and Incorrect Motion for Push-Up Counter Using OpenPose, *Proc. of IEEE 16th International Conference on Automation Science and Engineering (CASE '20)*, pp. 1389–1394 (Aug. 2020).
- [12] A. Ali: Measuring Soccer Skill Performance: A Review, *Journal of Medicine and Science in Sports*, Vol. 21, No. 2, pp. 170–183 (Jan. 2011).
- [13] W. Dardouria, M. A. Selmi, R. H. Sassi, Z. Gharb, A. Rebhi, and W. Moallac: Reliability and Discriminative Power of Soccer-Specific Field Tests and Skill Index in Young Soccer Players, *Journal of Science and Sports*, Vol. 29, No. 2, pp. 88–94 (Apr. 2014).
- [14] Mirkov, Dragan, Nedeljkovic, Aleksandar, Kukolj, Milos, Ugarkovic, Dusan, Jaric, and Slobodan: Evaluation of the Reliability of Soccer-Specific Field Tests, *Journal of Strength and Conditioning Research*, Vol. 22, No. 4, pp. 1046–1050 (July 2008).
- [15] A. Ali, C. Williams, M. Hulse, and A. Strudwick: Relia-

- bility and Validity of Two Tests of Soccer Skill, *Journal of Sports Sciences*, Vol. 25, No. 13, pp. 1461–1470 (Nov. 2007).
- [16] R. C. Jackson, S. Warren, and B. Abernethy: Anticipation Skill and Susceptibility to Deceptive Movement, *Journal of Acta Psychologica*, Vol. 123, No. 3, pp. 355–371 (Nov. 2006).
- [17] R. C. Bruland and M. Schmidt: Response Bias in Judging Deceptive Movements, *Journal of Acta Psychologica*, Vol. 130, No. 3, pp. 235–240 (Mar. 2009).
- [18] M. Weigelt, I. Guldenpenning, and Y. S. Weinrich: The Head-Fake Effect in Basketball is Based on the Processing of Head Orientation, but Not on Gaze Direction, *Journal of Psychology*, Vol. 11, No. 10, pp. 1493–1510 (Oct. 2020).
- [19] I. Guldenpenning, W. Kunde, and M. Weigelt: A Review Article on Deceptive Actions in Interactive Sports, *Journal of Frontiers in Psychology*, Vol. 8, No. 917, pp. 1–12 (May 2017).
- [20] M. J. Wright and R. C. Jackson: Deceptive Body Movements Reverse Spatial Cueing in Soccer, *Journal of Public Library of Science ONE*, Vol. 9, No. 8, pp. 1–9 (Aug. 2014).
- [21] G. Henry, B. Dawson, B. Lay, and W. B. Young: Effects of a Feint on Reactive Agility Performance, *Journal of Sports Sciences*, Vol. 30, No. 8, pp. 787–795 (Mar. 2012).
- [22] S. Albawi, T. A. Mohammed, and S. A. Zawi: Understanding of a Convolutional Neural Network, *Proc. of the International Conference on Engineering and Technology (ICET '17)*, pp. 1–6 (Aug. 2017).
- [23] L. Breiman: Random Forest, *Journal of Machine Learning*, Vol. 45, pp. 5–32 (Oct. 2001).
- [24] W. Huangab, Y. Nakamoria, and S. Y. Wangb: Forecasting Stock Market Movement Direction with Support Vector Machine, *Journal of Computers and Operations Research*, Vol. 32, No. 10, pp. 2513–2522 (Oct. 2005).
- [25] A. Altmann, L. Tolosi, O. Sander, and T. Lengauer: Permutation Importance: a Corrected Feature Importance Measure, *Journal of Bioinformatics*, Vol. 26, No. 10, pp. 1340–1347 (May 2010).