

## 232 足底圧力分布の解析と機械学習によるフリースロー動作の評価

## Free-Throw Recognition Using Plantar Pressure Distribution Analysis and Machine Learning

○学 中村 恒平 信州大学理工学系研究科

准 トッド パタキ 信州大学若手育成拠点

Kohei NAKAMURA, Shinshu University, Tokita,  
Ueda city, Nagano

Todd C PATAKY, Shinshu University

Key Words: &lt;Key Words&gt;

foot biomechanics

basketball

pattern recognition

## 論文要旨

Free-throws are essential to basketball game outcomes, but there are no existing methods for training athletes with objective free-throw feedback. This study analyzes free-throws by measuring plantar pressure (PP) distributions during free-throw movements and proposes a new method for developing free-throw feedback using PP-based machine learning. PP data were collected from seven university basketball players who performed 50 free-throws. Most subjects had at least one PP parameter (e.g. maximum pressure, center-of-pressure velocity) that significantly differed between success and failure ( $p < 0.05$ ). Additionally, optimally separating PP parameters were unique to each subject. A trained computer was able to predict free-throw results of three follow-up subjects, alternately using support vector machines and k-nearest neighbors, with average classification rates of 0.69 and 0.63, respectively. These results suggest the possibility of new methods for developing free-throw skills using PP feedback.

## 1. 導入

## 1-1 フリースローの重要性

バスケットボールにおけるフリースロー(FT)は、試合の勝敗に大きな影響を及ぼす要因のひとつである。FTの重要性を取り上げた報告は、1994年に発表されたKozzerらの論文がある<sup>[1]</sup>。NCAA ディビジョン1の男子バスケットボールの490試合において、試合時間の残り5分以降の両チームの得点のうち35%はFTによるものであるという。得点差が9点差以内で勝敗がついた場合、勝利チームの残り5分間の得点は、48%がFTによる得点であり、残り1分では69%であるという報告もされている。

以上のことから、FTが試合(特に終盤)で重要であり、FTを確実に成功させることは、勝利のための必須の条件であるといえる。多くのチームにとって、同等の実力を有する相手との試合は重要なものであると思われるが、その試合で相手に打ち勝つためにはFTを確実に成功させることが求められる。また選手個人についても、FTの成功率が高いことはひとつのステータスとなり得るし、FT成功率の低い選手は、接戦の試合終盤ではコート上に立つことができない可能性が高いことが示唆されている。

## 1-2 先行研究

FTの重要性が強く説かれているにもかかわらず、動作の客観的評価による生体自己制御を取り入れたFTトレーニング方法について研究している例は、今のところほとんど存在しない。先行研究の多くは、選手がFTを投じるときの精神面に注目した心理学的研究である<sup>[2]</sup>。

また、FT熟達者と未熟者を対比した生体工学的研究も多く行われてきた。モーションキャプチャを用いた多くの先行研究において、FT成功率に大きく影響を及ぼす要因として、動作の再現性が挙げられ、重要視されている<sup>[3][4]</sup>。理論的には、毎回同じ動作を繰り返せば、FTを確実に成功させることが可能である。生体が行う動作であるので、毎回異なる揺らぎが生じることは不可避である。体力の消耗、怪我、精神的圧迫、環境の差異など様々な要因が身体動作に影響を及ぼす中で、ゆらぎを最小限に抑え、動作の再現性を高めることがFT成功率を向上させるために必要である。

フォースプレートを用いたFT動作の動力学的解析もまた、

先行研究により行われている<sup>[5]</sup>。この研究によれば、FT動作は床に足をつけた状態で行われるが、重心運動の力学的観点では、ジャンプ動作に極めて近い動作であると指摘されている。また、繰り返しの実験により得た重心変量の波形データの近似性から、FT成功率と動作の再現性の関連性を指摘している。

これらの研究がFTトレーニングに容易に結びつかない理由のひとつは、客観的データの取得は困難が伴うことにあると思われる。フォースプレートは巨大で重量があり、バスケットコートに設置することができない。モーションキャプチャによる解析を行う場合、カメラやマーカーのセットアップに多くの時間を要することになる。

## 1-3 足底圧力分布

足底圧力計測は可搬性の中敷型の圧力計測器によって行うことができるので、その他の工学的計測方法に比べて汎用性が高い(Pedar system)。また、詳細かつ多量なデータを簡単に記録できることも足底圧力計測の優位性といえる。圧力計測器のそれぞれのセンサが一定時間ごとに荷重を感じすることで圧力は計測されている<sup>[6]</sup>。つまり(各センサへの荷重 × 時間)によるボクセルの集積が圧力分布データである。その中からある部分のみに注目する(例えば圧力中心の変移、足の拇指球にかかる圧力など)ことで、注目するデータについての定量的な分析を行うことが可能となる。

近年、足底圧力を圧力計測器により計測する研究が功績を伸ばしつつあり、多くの臨床的応用や、個人認証システムなどへの利用の可能性が示唆されている<sup>[7][8]</sup>。さらに、NIKE+のスマートフォンをインターフェースとするセンサ内蔵型シューズなどの新技術によって、FT動作の客観的データの取得は、今後より容易になるとと思われる<sup>[9]</sup>。

## 1-4 本研究の目的

本実験の最終的な目的は、足底圧力の解析を利用した客観的FTフィードバックシステムを構築することである。システム構築のためには、さまざまな基礎的実験を行う必要がある。特に必要である成果は、PCを、足底圧力データからFT成功と失敗を判別するように学習させることは可能

かどうか、である。本論文においては第一段階として、①足底圧力データから成功時と失敗時における差異を判断すること、②PCが成功と失敗を判別するように学習することが可能かどうか検討することを主要な目的とする。

## 2. 実験方法

### 2-1 計測器具

圧力計測器には Pedar X (NOVEL, Munich, Germany)を用いた。Pedar X はインソール型の圧力計測器であり、足とシューズの中敷の間に挟んで使用する。片方 99 個の静電受容センサによって構成され、サンプリングレートは 50 Hz である。Bluetooth によって、PC 上にデータが転送され、リアルタイムの観測が可能である。

また、ビデオカメラ (Victor, Kanagawa, Japan) も同時に計測で用いることにより、Pedar X の FT 動作データにおいて、ボールが手から離れる瞬間 (リリース) のフレームを算出する。ビデオカメラのサンプリングレートは 30Hz である。

### 2-2 計測手順

図 1 は実験の様子を表した略図である。被験者は Pedar X を装着した状態で、フリースローライン上の規定された位置 (両足そろえた状態で 30 cm 幅) に立つ。FT ライン上の被験者がゴールと正対したとき、ゴールと垂直な方向を X 方向、水平な方向を Y 方向とする。

- ①: 観測者が合図をし、データ記録を始めたなら、被験者は任意のタイミングで FT 動作を開始する。
- ②: 被験者は動作の最初に片足を一度上げて、下ろす。それから FT 動作を行う。
- ③: ①, ②を 50 回行う。

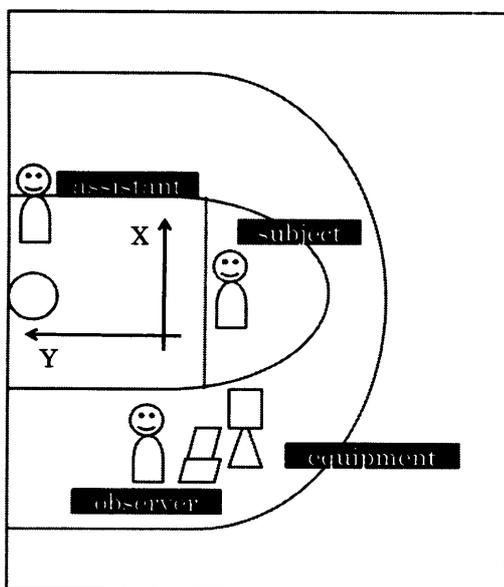


Figure 1 Experimental setup of free-throw

### 2-3 被験者

最初に、被験者として信州大学男子バスケットボール部の部員の協力を得た (実験 1)。被験者は怪我や病気による動作の支障はなく、全員右利きである。被験者の足底圧力分布が成功時と失敗時で差異を有するかどうかを調べる。しかし実験 1 における被験者の平均 FT 成功率が 80.6 % と高く、成功

時と失敗時の比較には適さない。そこで追加実験として、3 人の被験者のデータを採取した (実験 2)。こちらの平均成功率は 48.7 % であり、成功数と失敗数の比率は均等に近いものになっているため、比較において有用なものとなっている。表 1 は、それぞれの実験の被験者の情報である。

実験 1 の実験場所は、3 人の被験者は信州大学繊維学部キャンパス体育館、4 人の被験者は信州大学教育学部キャンパス体育館において行った。いずれの被験者も通常練習の後、データを採取した。実験 2 の被験者は、信州大学繊維学部キャンパス体育館において、十分な練習後にデータを採取した。

Table 1 Subject characteristics. Averages, with s.d. in parentheses. Subjects consist of basketball team are in "team". Follow-up subjects are in "follow-up".

	team	follow-up
number of subjects	7	3
age (years)	21.0 (1.20)	27.0 (7.79)
mass (kg)	79.9 (5.59)	66.3 (3.40)
height (cm)	183.9 (5.77)	175.3 (4.71)
experience (years)	8.0 (1.31)	4.3 (2.36)
FT success (%)	80.6 (8.93)	48.7 (2.49)

### 2-4 データの前処理

Pedar X により採取された圧力データは、ASCII ファイルとして PC に転送する。転送されたデータは、Enthought Python Distribution (version 7.0) のプログラミングソフト Python 2.7 を用いて解析を行う (Enthought Inc, Austin, USA)。Pedar X により採取したデータについて、各センサが FT 動作中に感知した最大圧力を表示するようなプログラム処理を行った例を、図 2 に示した。

ビデオカメラにより採取された映像データは、動作開始と動作終了時のフレームを調べるため、AVS Video Converter (version 8.0.1.492) を用いてデータの形式を変換して保存する (Online Media Technologies Ltd, London, United Kingdom)。フレームを調べる作業は VirtualDub-1.9.11 (VirtualDub.exe) を用いる (Free Soft Foundation Inc, Cambridge, USA)。

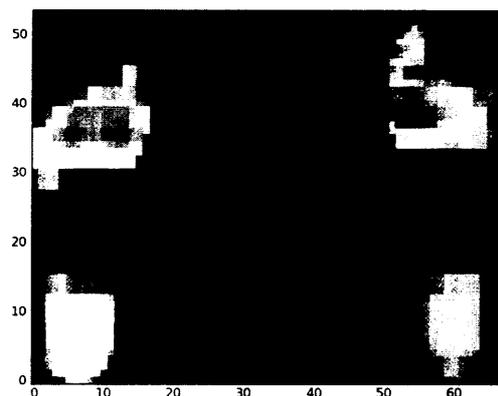


Figure 2 An instance of max pressure distribution during FT movement by using Pedar X

### 2-5 時間同期

計測したデータは Pedar X による圧力データとビデオカメ

ラによる映像データの2種類であり、圧力データにおけるリリースのフレームを特定するために、2つのデータを同期させる必要がある。

動作時間を $\Delta t$ とし、動作開始(被験者が上げた足を地面につけた瞬間)を $t_0$ 、動作終了(ボールをリリースする瞬間)を $t_1$ とすると、式(1)が成り立つ。

$$\Delta t = t_1 - t_0 \quad (1)$$

映像データにおける $t_0$ を $\text{frame}_{v0}$ 、 $t_1$ を $\text{frame}_{v1}$ とし、サンプリングレートを $\text{SR}_v$ とすると、映像データにおける $\Delta t$ は次のようになる。

$$\Delta t = \frac{(\text{frame}_{v1} - \text{frame}_{v0})}{\text{SR}_v} \quad (2)$$

圧力データにおける $t_0$ を $\text{frame}_{p0}$ 、 $t_1$ を $\text{frame}_{p1}$ とし、サンプリングレートを $\text{SR}_p$ とすると、圧力データにおける $\Delta t$ は次のようになる。

$$\Delta t = \frac{(\text{frame}_{p1} - \text{frame}_{p0})}{\text{SR}_p} \quad (3)$$

$\text{frame}_{p1}$ を算出することで、圧力データにおけるリリースフレームを特定することができるので、式(3)を変形する。

$$\text{frame}_{p1} = \text{frame}_{p0} + \Delta t \times \text{SR}_p \quad (4)$$

式(4)に式(2)を代入することで、圧力データにおけるリリースフレームを特定することができる。

## 2-6 比較要素

足底圧力分布データからは、多くの成功と失敗における比較が可能な要素を抽出することができる。比較要素の例は、接地面積(Contact Area, CA)や、その変移速度、圧力中心(Center Of Pressure, COP)や、その変移速度、足底のある部分における圧力(Point Of Interest, POI)などである。成功と失敗の足底圧力分布を比較したとき、これらの要素が有意差を示した場合、これらはFTを失敗した原因と関係していると考えられる。有意差を持つ比較要素を差異要素と呼ぶこととする。有意差を持つかどうかの判断基準には、t-検定を用いる( $p < 0.05$ で有意差ありとする)。

## 2-7 機械学習による判別

差異要素が、実際にFTの成否に影響を及ぼしているのかわかり、機械学習による判別で調べる。事前に機械学習のプログラミングを構築しておき、得られたデータをPCに与えることで、PCが自動的にあるデータについて成功と失敗を判別することが可能となる。その判別の正確性がFTトレーニングにおいて重要となる。初期段階であるので、2次元空間(2つの差異要素についての判別)における成功群と失敗群の機械学習を行う。

判別がどの程度優れているかという指標には分類率(Classification Rate, CR)を用いて表す。CRは以下の式によって算出する。

$$\text{CR} = \frac{\text{正しく分類したデータ数}}{\text{分類を行った全てのデータ数}} \quad (5)$$

被験者一人につき50のデータがある(オリジナルデータ)。そのうち10のデータをランダムで抜き出す(この10のデータをテストデータと呼ぶ)。残りの40のデータを、PCに学

習させ、成功と失敗の判別の基準を作る(この40のデータをトレーニングデータと呼ぶ)。それからテストデータを学習したPCによって、結果を予測させることで $\text{CR}_i$ を得る。この操作を5回行うことで、 $\text{CR}_1 \sim \text{CR}_5$ を得る。これらの平均値を取ることで、その被験者のCRを算出する。

機械学習の判別の手法は、2種類用いた。その1つはサポートベクターマシン(Support Vector Machine, SVM)である。SVMは、高次元特徴空間において線形関数の仮説空間を用いる学習システムである<sup>[10]</sup>。SVMの中でも基本的なアルゴリズムである線形学習マシンのモジュール(Linear SVM)を用いる。Linear SVMでは、判別すべきデータ群(FTの成功と失敗で有意差のある要素)を超平面によって分類する。2次元空間の場合、超平面は成功群と失敗群を分類する直線である。超平面は、超平面と直交する重みベクトル $\mathbf{w}$ によって傾きが決定され、また、バイアス( $b$ )という量によって超平面自身に平行に動くことで形成される。正しく分類されなかった場合、 $\mathbf{w}$ と $b$ の式は更新され、すべてのデータが正しく分類されるまで計算は繰り返される。図3はLinear SVMによる分類の例である。

もう1つの手法は、k近傍法(k-Nearest Neighbor, k-NN)である。k-NNは、特徴空間におけるあるひとつのデータについて、最も距離的に近いデータに基づいて分類を行う統計分類の手法である。今回の分類では、 $k=1$ で分類を行う。 $k=1$ のときは最近傍のデータによって分類される。図4はk-NN( $k=1$ )による分類の図である。

今回の実験では、2つの差異要素によって成り立つデータについて機械学習の分類を行うことはすでに述べたが、分類する前に、要素の正規化を行う必要があることについて言及する。例として、2つの要素がそれぞれ「圧力中心の変移速度」、「接地面積」であった場合、この2つの値を比較すると、値が大きく異なってしまう。2つの値を正規化しない状態で機械学習を行うと、分類の結果に問題が生じる可能性がある。したがって、データを構成する2つの要素は、式(6)によって正規化を行う。ただし、差異要素の値を $x_i$ 、平均値を $\bar{x}$ 、標準偏差を $x_{sd}$ 、正規化した値を $n_i$ とする。

$$n_i = \frac{x_i - \bar{x}}{x_{sd}} \quad (6)$$

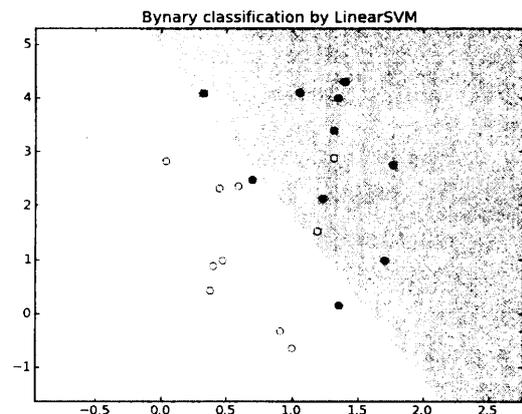


Figure 3 An instance of classification by Linear SVM

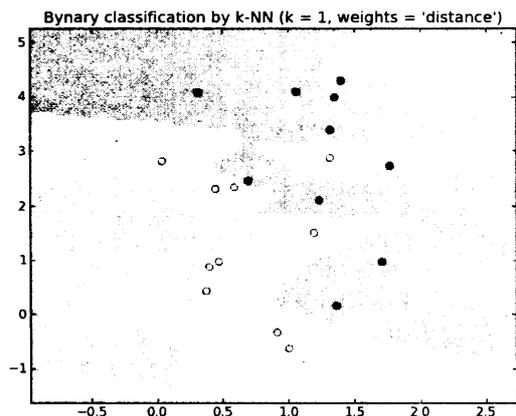


Figure 4 An instance of classification by k-NN (k = 1)

### 3. 結果

#### 3-1 差異要素の発見

実験1の被験者は、信州大学バスケットボール部の部員で、平均FT成功率80.6%と高い成功率であった。様々な要素についてt検定を行った結果、被験者7人中6人はp値が0.05を下回る差異要素を発見することができた。残りの一人の被験者は差異要素を持たなかったものの、一つの要素は有意差にかなり近い値を示した。表2は実験1の各被験者の差異要素のうち、最も差異の大きかった要素である。

実験2の被験者は、FTの成功率が48.7%とそれほど成功率は高くない。t検定を行った結果、実験1の被験者と比べて、全ての被験者が多くの差異要素を持つことがわかった。表3は実験2の各被験者の最も差異の大きい差異要素である。

Table 2 Best variables of subjects in experiment 1. Frame number 0 is the release (50Hz). COP-Y is center of pressure of Y-axis. CA is contact area. POI is point of interest.

Sbj	Variable	Frame	p
1	Mean velocity of COP-Y	-40~-35	0.010
2	Mean velocity of COP-Y	-30~-25	0.003
3	CA of Left foot	-5	0.035
4	Mean velocity of CA of right foot	-30~-25	0.090
5	POI at medial forefoot of right foot	-12	0.049
6	Mean velocity of COP-Y	-5~0	0.025
7	POI at hallux of right foot	0	0.030

Table 3 Best variables of subjects in experiment 2. COP-X is center of pressure of X-axis.

Sbj	Variable	Frame	p
1	Velocity of COP-X	-30	0.001
2	Velocity of COP-X	-26	0.001
3	Velocity of CA of both feet	-24	0.001

#### 3-2 差異要素の機械学習による分類

実験2の被験者3人から得られた差異要素のうち、最も有意差の大きかったものを2つ選び、SVMとk-NNによって分類し、2-6の方法によってCRを算出する。成功と失敗でデータにまったく偏りがない場合、機械学習によるCRは50%となる。したがって、CRは常に50%以上となる。

表4は3人の被験者のCRを表している。全ての被験者に

おいてCRは、SVMがk-NNを上回る結果となった。

Table 4 CR lists using SVM and k-NN in experiment 2. Two best variables were chosen.

Subject	SVM	k-NN
1	0.64	0.62
2	0.74	0.60
3	0.68	0.66

### 4. 考察

#### 4-1 バスケットボール選手について

実験1では、バスケットボールチームに所属している選手が被験者であった。そのためFT成功率は高く、成功数と失敗数の割合がかなり不均一なものとなった。それでも被験者7人中6人にはいくつかの差異要素を見ることができた。FTがかなり得意な者であっても差異要素が見られたことは、足底圧力分布計測による動作解析の有用性を示唆するものである。実験における試投数を増やし、同数の成功と失敗を比較すれば、より多くの差異要素を発見できるのではないかとと思われる。

また、7人中6人の被験者がCOP-Yに関係する差異要素を持つことがわかった。FTを投じるとき、ほとんどの選手は左右の身体動揺を防ぐことを重要視するように指導されている<sup>[11]</sup>。それに比べて、前後の身体動揺には多くの注意が払われていないため、このような結果になったと考えられる。

#### 4-2 未熟被験者について

実験2では、FT成功率が50%程度である被験者を集めて実験を行った。ほぼ同数の成功と失敗のデータをt検定によって比較したところ、平均30ほどの差異要素が各被験者に見られた。

実験2では、実験1とは異なりCOP-Xに関連した差異要素が多く見られた。COP-Yについても有意差は見られたものの、COP-Xについて、より大きな有意差を多く見ることができた。これは、実験2の被験者は実験1の被験者と比べ、FTの技術が未熟であるため左右の身体動揺が頻繁に起こり、それが失敗の最も大きな原因となったと考えられる。また、最大差異要素におけるp値が実験1の被験者に比べてかなり小さいことも注目すべきことである。

これらのことから、FT成功率の低い被験者ほど差異要素の数が多く、また差異の度合いも大きい傾向にあると思われる。

#### 4-3 機械学習について

実験2の被験者において、最大差異要素を2つ選び機械学習を行った。SVMとk-NNによる2種類の方法を採用したが、いずれの被験者もSVMによる分類率のほうが高かった。機械学習による分類の方法は他にも様々な方法があるので、今後試していき、最も適したものを採用する予定である。

今回の実験における被験者のFTの結果を正しく分類できた割合は、6~7割程度であったが、これは十分に意味のある結果であると思われる。バスケットボール選手は、足底圧力分布計測によるFTトレーニングの手法を取り入れることで、自分のFT動作における足底圧力の（ひいては動作の）成功と失敗を比較したときの差異を知ることができる。そして機械学習によって、成功と失敗が分類され、選手に明確なFT失敗の原因、またFTが成功しやすい領域が提示される。選手がFTを試投し、データがたくさん集まるほど、より正確な分類を行うことができる。選手がFTの上達に従ってシュ

ートフォームが変異していくことが予想されるが、それにもなって機械学習の分類の仕方も柔軟に変化していくことは、機械学習によるトレーニングの優れた点である。

今回の実験では、機械学習を行う対象の差異要素を、全データについてのt検定によって抽出した。より厳密な最大差異要素を抽出するためには、「2-6 機械学習による判別」においてランダムに選択した40のトレーニングデータのみについて、毎回t検定を行う必要がある。そうすることによって、より精密な分類を行うことができる。また、CRを上昇させ、より明確に成功と失敗を分類するため、データを構成する差異要素数を増やすことが可能である。今回は2つの差異要素によって構成されたデータを用いており、分類は2値クラス分類であった。差異要素数はいくらかでも増やすことは可能であり、多クラスのクラス分類を行うことになる。それによって、より成功と失敗の分類が行いやすくなり、CRは7~8割ほどに上昇すると予想される。しかし選手の立場からすると、そうすることによって修正すべき動作上の問題点が増加することになり、FTトレーニングとして逆に不便なものとなりかねない。よって、選択する差異要素の数は必要最低限のものとする必要がある。

#### 4-4 今後の課題

NCAA ディビジョン1のあるチームの試合と練習におけるFTの成功率を比較したところ、練習におけるFT成功率のほうが有意に高いことがKozarらにより報告されている<sup>[2]</sup>。FTの練習は5~6回連続で投げる方法であった。しかしFTの練習の1投目のみの成功率を、試合におけるFT成功率と比較した場合、有意差は認められなかった。練習におけるFT成功率が高いのは、5~6本連続で試投する間に選手が「リズムに乗る」ためであり、FTの練習は1本ずつ、もしくは2本のセットで行われるべきであると主張されている。またKozarらは、選手は連続でFTの練習を行い、動作を「維持」するのではなく、試合と同様にFTレーンに立つたびにFT動作を正確に「呼び起こす」ことが重要であると主張している。ここで言及されているように、本実験によるトレーニングにおいても可能な限り実際の試合に近い状況で行われることは効果的であると思われる。

Pedar Xを計測に用いる場合、被験者の動きが制限されてしまうため、実際の試合と同様の状況を用意することは困難である。そこで、圧力測定器と記録装置が完全に分離しているNIKE+を用いることで、多くの問題が解決すると思われる。NIKE+を用いれば、実際の試合中に投げられるFT動作を計測することが可能であり、より実証的なFTトレーニングを行うことが可能である。

また、今回の実験では、データを成功と失敗のみに着目して分類を行った。それでも十分な効果を得ることはできると思われるが、ボールがゴールにはいる入り方(ボールの軌道)については考慮されていない。ボールの軌道を計測する装置(もしくはボールの初速度ベクトルを計測する装置)を用いることで、足底圧力の分布データからボールの軌道を予測する機械学習を構築することを将来的に行う予定である。これにより、成功と失敗の身から判断するよりも効果的なFTトレーニングを構築できる可能性がある。

#### 5. 謝辞

今回、研究の被験者として協力して下さった信州大学男子バスケットボール部員、また、信州大学繊維学部の方々にこの場を借りて感謝の意を表します。

#### 6. 参考文献

- 1 Kozar, B. & Vaughn, R. E., Lord, R. H., Dye, B. 1994 Importance of free-throws at various stages of basketball games. *Perceptual and Motor Skills* 78, 243-248.
- 2 大神訓章, 児玉善廣, 野寺和彦, 金 亨俊 2012 バスケットボールゲームにおけるシュートのブレに関する分析的研究, 山形大学紀要(教育科学), 15(3), 37-48
- 3 塩見哲大, 湯浅景元 2002 バスケットボールのフリースローにおけるボール運動および関節運動の再現性, 中京大学体育学論叢, 44-1, 29-34.
- 4 陸川 章, 山田 洋, 加藤達郎, 植村隆志 2005 大学男子バスケットボール選手におけるフリースロー・シュート技能の評価, 東海大学紀要体育学部, 35, 7-12.
- 5 久場里志, 北湯口純, 奥山秀雄, 大道 等, バスケットボール・シュート動作における重心変量解析, 082 教A03505 427
- 6 Rosenbaum, D & Becker, H. P. 1997 Plantar pressure distribution measurements. *Technical background and clinical applications. Foot and Ankle Surgery* 3, 1-14.
- 7 堀川悦夫, 樋口 進, 松下幸生, 荒井啓行, 佐々木英忠 2001 アルコール依存症患者における身体動揺の分析, 東北大医短部紀要, 10(2), 161-166.
- 8 Pataky, T. C., Mu, T., Bosch, K., Rosenbaum, D. & Goulermas, Y. 2011 Gait recognition: highly unique dynamic plantar pressure patterns among 104 individuals. *J. R. Soc. Interface* doi:10.1098/rsif.2011.0430
- 9 [http://www.nike.com/jp/ja\\_lp/lp/basketball](http://www.nike.com/jp/ja_lp/lp/basketball)
- 10 Nello Cristianini, John Shawe-Taylor 著, 大北 剛 訳, 2005 サポートベクターマシン入門
- 11 Palladino, G. 1980 The Free Throw—An In-Depth Analysis, *The Basketball Clinic*, 7-11.
- 12 Hays, D. & Krause, J. 1987 Score on the throw. *The Basketball Bulletin*, winter, 4-9.