

# 足圧分布センサを用いた姿勢認識手法

大西鮎美<sup>1</sup> 寺田 努<sup>1,2</sup> 塚本昌彦<sup>1</sup>

**概要：**複数の機器を装着することなく、日常的に着用するシューズのみから足以外の情報である姿勢などを推定できれば、より快適で、広範囲なサービスに応用が可能となる。シューズを用いたセンシング例は多くあるが、足以外の身体の状態については詳細に検討されていない。そこで本研究では、シューズの中に搭載した足圧分布センサを用いて足裏圧力から姿勢や動作の推定を行なった。22種類の姿勢や動作について4種類の分類器で認識精度を評価し、RandomForestで25cm以上のシューズサイズの被験者は片足105エリア、25cm未満の被験者は片足84エリアの特徴量の寄与度を算出した。さらに、寄与度の高かった点について認識率を評価することで、最適な計測点を検討した。最も寄与度の高い1点で認識した場合にF値が最も高くなった被験者で全動作の平均が0.53であった。また、寄与度が最も高い点と寄与度が2番目に高かった左右対称な点の2点(片足1点ずつ)で認識精度を評価したところ、最も精度の高かった被験者で平均のF値が0.90となった。特徴量を630個に増やした際も、かかとの内側部分に関しては、寄与度が上位5位に入ることは無かった。実験全体を通して、足先付近が寄与度の高い点が多く、被験者ごとにセンサ位置を変えることができない環境で、今回のような日常的なコンテキストを認識する場合、計測点を一点にしぼるのであれば足先の点が有力ではないかと考えられる。足圧を用いたアプリケーション例として、足圧分布をリアルタイムに光で提示するPressureLightningShoes(PL-Shoes)を実装した。

## 1. はじめに

近年、コンピュータの小型化や軽量化により、常時コンピュータを身に付けるウェアラブルコンピューティング環境が整ってきている。ウェアラブルコンピューティング環境では、身体にセンサを多く取り付けることで、より詳細に人の動作データを取得することが可能だが、複数の機器の装着には手間やコストがかかるため、日常生活において、ウェアラブルデバイスは日常的に使用するものに統合されていることが望ましい。また、機器の充電はシステム利用者にとって負担であり、継続利用の妨げとなる大きな要因である。これを解決するためには、最終的には充電をせずに使い続けるシステムを開発することが挙げられる。神野らが開発した圧電薄膜[1]は、圧力により発電可能であるため、この圧電発電を用いれば、無電源でセンシングを行なうことが可能であると考えられる。そこで、我々は日常的に着用するシューズに着目した。シューズを履くだけでセンシング可能であり、また、日常シーンだけでなくスポーツやエンタテインメントなど、応用シーンも多い。さらに足圧により発電することで、充電の問題も解決される。し

かしながら圧電発電は開発途中段階であり、応用先の検討段階である。将来的に発電できるシューズが登場することを見越して、本研究では、シューズに搭載された足圧分布センサを用いて、足圧情報から身体の姿勢や動作の推定を行なう手法を提案する。また、発電量を考慮すると、より少ないセンサ数で姿勢や動作の推定が行なえることが望ましいため、日常的な姿勢と動作を高精度に認識できる最適なセンサ数とセンサ位置の検討を行なう。

本論文の構成を以下に述べる。2章で関連研究を紹介し、3章ではシステム構成について述べる。4章で予備実験を行い、5章で評価実験について述べ、6章で足圧計測を用いて実装したアプリケーションについて説明し、最後に7章で本論文をまとめる。

## 2. 関連研究

本章では足圧分析に関する研究と日常行動の認識に関する研究およびウェアラブルシステムを用いた足圧計測に関する研究について述べる。

### 2.1 足圧分析に関する研究

足裏にかかる圧力値を計測し、分析する研究は多くある。Zhouらは、カーペット型の圧力センサシートを用いて、歩き方から個人識別を試み、76.9%の精度で識別ができてい

<sup>1</sup> 神戸大学大学院工学研究科  
Graduate School of Engineering, Kobe University  
<sup>2</sup> 科学技術振興機構さきがけ  
Japan Science and Technology Agency, PRESTO

る [2]. Sousa らは、圧力センサシートと装着型の加速度センサから人のトラッキングや個人識別を行っている。那須らはドアの前に Wii board を設置し、ドア開閉時の加重変化と足圧中心移動軌跡から個人識別を行っている [4]。これらの研究は歩行や足圧変化の個人差に着目し、足圧分析から個人識別を行っており、足圧から姿勢や動作の認識は行っていない。中澤らは 50cm 角のタイル状の圧力センサシートを用いてスマートハウスのための屋内人物の位置と姿勢を推定する手法を提案している [5]。このような圧力センサシートは場所に依存するため、家以外での日常行動を記録することは難しい。本研究では、場所に依存せず、普段から日常的に着用するシューズに着目し、安価な最少構成の圧力センサの値から動作や姿勢を識別する。

## 2.2 日常行動の認識に関する研究

Starner らは、カメラを用いてユーザの行動を認識している [6]。カメラを用いてユーザの行動を認識する研究は数多く行なわれているが、場所に依存してしまう。このような日常行動の認識にはウェアラブルセンサを用いることで場所に依存せず計測することが可能となる。ウェアラブルセンサを用いた日常のコンテキストウェアシステムとして、Tsubaki らはストレッチセンサを用いて身体の周径変化から 11 種類の動作や姿勢を認識している [7]。しかし、身体の腕や足、腹部などの複数部位にセンサを密着させなければならない。ジェスチャ認識には加速度センサが用いられることが多く、Murao らの研究 [8] では、ボード上に配置された 9 種類の加速度センサと角速度センサを利用して 27 種類のジェスチャを認識し、センサの位置や数を変えることで認識精度を評価している。Watanabe らは、ユーザの腕に小型の超音波スピーカを、胸にマイクを装着することで、動作を行った際の超音波音量の変化とドップラー効果による周波数変化を利用し、ジェスチャを認識している。また、Microsoft 社の Kinect [10] は、赤外線によりユーザの姿勢やジェスチャを認識できる。これらの研究やデバイスでは外見から判断できるような動きや姿勢は取得できているが、どちらの足に荷重がかかっているかのような腕が動かないコンテキストや重心変化を取得することは難しい。また本研究のように普段から身に着け、メンテナンスも比較的容易なシューズで日常的なコンテキストを認識することができれば、ユーザにとっては負担が少ないと考えられる。

## 2.3 ウェアラブルシステムを用いた足圧計測に関する研究

圧力センサシートを用いて歩行分析をする際はセンサの配置については考えなくてよいが、ウェアラブルデバイスを用いて足裏圧力を計測する場合、消費電力や実用性を考えると、とりたてデータを高精度に取得可能なセンサ配置について考慮する必要がある。シューズや靴下などのウェ

アラブルシステムを用いてセンシングを行う研究について、どのようにセンサ配置を採用しているかに着目しながら述べる。大橋らは、14×5 の足圧センサが配置されたセンサを用いて足圧分布の変化から路面形状を判別するシステムを構築している [11]。これは、シューズのアウトソールの上にさらに足圧計測のためのセンサシートをとりつけるというもので、路面変化を直接的にうけて識別率 78.2% で 3 段階に判定することはできるが、センサを保護するものがなく、日常的に使うには破損の心配がある。深堀らは、Sockswitch という靴下型デバイスを開発し、ユーザ定義型の微小な足裏ジェスチャによるインターフェースを構築している。ジェスチャを行うために足の指を中心に片足に 8 点ずつ計 16 点の圧力センサを配置している [12]。Hayama らは、片足に圧力センサが 11 点配置されているインソール型の圧力センサを用いて足圧を測定し、フォースプレートで取得した実測値と比較することで足圧中心軌跡の推定を行なっている [13]。この研究では装着者個人ごとの足底荷重の特徴をみてセンサ配置を決定している。堀江らは、平地歩行、平地走行、階段昇降、坂道昇降における足圧の解析を行っている [14]。使用した足圧センサシートは空間分解能 5mm のものをシューズ内の中敷に装着して計測を行っており、今後の課題として実用化のために数個のセンサで実現することを挙げている。Zhou らはサッカーシューズのボールを蹴る際に接触がある 3 箇所に取り付けた圧力センサシートからボールを蹴る方向を推定している [15]。Talavera らは欧州の WIISEL というプロジェクトでワイヤレスな片足 14 点インソールを開発し、歩行データを大規模な実証実験により集めていて、主に高齢者を対象として転倒リスク分析を行っている [16]。このインソールは、非接触充電かつ BLE 通信であるため、コネクタやケーブル類がなく、低消費電力を意識した設計がなされているが、センサ配置については詳細に検討されていない。杉本らは、片足 7 点の圧力センサを内蔵した足圧計測シューズを開発し、歩行、走行などの 7 種類の日常行動を認識している [17]。7 点からのとりうるすべての組み合わせから 5 点を選べばどの点を選ぶかに関わらず認識率は 100% となっている。しかし、この 7 点のセンサ位置は筆者らが独自で決定しており、この 7 点に決定した明確な理由は述べられていない。結果として 7 点の中での認識率について述べるにとどまっており、本研究のように片足全体に圧力センサがある状態から議論するのは異なる。本研究では足裏全体に足圧センサが敷き詰められた状態で、日常的なコンテキストを対象とした場合にどの点が計測に有効であるか検討する。

## 3. システム構成

図 1 に足圧による姿勢認識手法の評価のシステム構成を示す。足圧データの取得には、medilogic 社の足圧分布計



図 1 システム構成

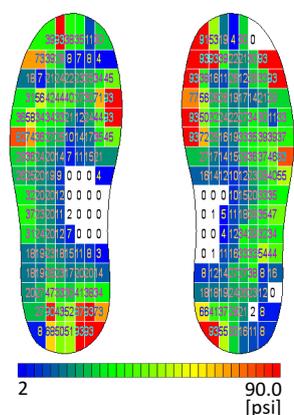


図 2 各点の圧力最大値

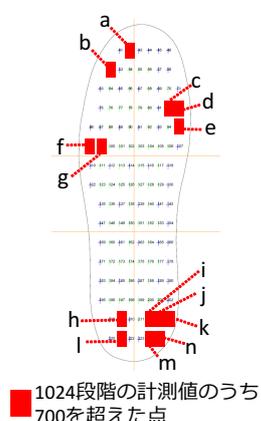


図 3 右足センサ配置図

測システム [18] を用いて片足 130 点の計 260 点の圧力値を取得し、Wi-Fi を介して PC に送信する。サンプリングレートは 100Hz に設定した。なお、確認用にビデオカメラを用いて映像データも取得する。

## 4. 予備実験

足圧からどの程度姿勢を推定可能か評価実験の項目を検討するために行った予備実験について述べる。

### 4.1 実験内容

男性被験者 1 名について図 1 のシステムを用いて、予備実験を行った。評価項目は基本的な姿勢や動作である直立、片足加重 (左右)、片足立ち (左右)、背伸び、ジャンプの 5 項目とし、各項目 60 秒間の足圧データを採取した。この時の足圧値の取り得る最大値は 90psi である。映像データから正解ラベルを作成し、片足 130 点の計 260 個の瞬時値を 1 データセットとして、データマイニングツール Weka[20] の J48 のアルゴリズムを用いて分類を行い、汎用性を評価するため、10 分割交差検証を行った。

## 4.2 予備実験の結果と考察

まず、片足の各圧力センサ 130 点の値をすべて用いて評価を行った。この場合、認識精度は F 値で 99.9% であった。図 3 に計測実験中の各センサの圧力値の最大値を示す。図 3 に示すように、まったく圧力のかかっていないセンサが存在するため、認識精度に寄与するセンサを選択する必要があると考えられる。そこで、計測実験中の圧力値の最大値が 1024 段階のうち 700 を超えるセンサを選択し、再度認識精度を算出した。図 3 より、右足の足圧分布では、圧力値の最大値が 700 を超えているセンサは片足全体の 10.7% に当たる 14 点存在し、左足では 13 点存在した。しかしながら、図 3 より左足の足圧値の最大値で 700 を超えている点はインソールの端に沿って最大値が出ている部分が多く、これらについては足圧ではなく、シューズ側面から受ける圧力である可能性が高いため、今回の予備実験では右足の 14 点のセンサ位置と対称な点で左足も評価を行なった。図 2 に圧力値が 700 を超えた 14 点のセンサ位置を示す。14 点の場合は 98.5% であった。次に 14 点について 1 点ずつの認識精度を評価した。表 1 にセンサ位置 14 点の各姿勢ごとの F 値を示す。表 1 より、 $i > g > e > j > k > m > n > d > f > c > h > l > b > a$  の順に認識精度が高かった。計測点 a, b, h, l については認識率が 0 となっている項目もあり、足が地面に着いていても評価に用いた圧力センサには接触していないなどの理由で圧力がかかっていなかったと考えられる。右足の最大値を基準として片足 14 点を評価に用いたため、最大値が認識精度に関わっているのであれば、片足加重や片足立ちといった項目については右足が左足より精度が良いと考えたが、上位 8 点中では点 n を除く 7 点で右足のほうが精度が高かった。

## 5. 評価実験

最少のセンサ構成で足圧変化から日常的な姿勢と動作の高精度な推定を実現するための最適な計測点を検討した。

### 5.1 実験内容

4 章で述べた予備実験と同様に図 1 に示した足圧計測システムを用いて、表 3 に示す 22 種類の日常生活を想定した姿勢または動作中の足圧データを採取した。男性 6 名と女性 4 名の計 10 名でいずれも 20 代である。被験者の身長、足のサイズおよび性別を表 2 に示す。それぞれ姿勢および動作が安定してから約 30 秒間の足圧データを採取し、これを 1 セット行なった。

### 5.2 認識手法

Medilogic の足圧分布計測インソールは、25cm 以上のシューズサイズの被験者は片足 130 点、25cm 未満のシューズサイズでは片足 107 点のセンサにより構成されている。本研究では最終的に市販の FSR402[19] のようなセンサを

表 1 各項目における認識率 (高精度上位 8 点)

	28 点	a	b	c	d	e	f	g	h	i	j	k	l	m	n
ジャンプ	0.95	0.44	0.18	0.69	0.54	0.79	0.36	0.49	0	0.15	0.12	0.16	0	0.13	0.17
直立	0.99	0.42	0.51	0.84	0.89	0.95	0.90	0.96	0.90	0.97	0.94	0.95	0.89	0.97	0.97
片足加重 (右)	0.99	0	0	0.76	0.76	0.88	0.70	0.89	0.65	0.97	0.85	0.81	0.63	0.80	0.76
片足加重 (左)	0.99	0	0.85	0.71	0.75	0.80	0.89	0.85	0.77	0.76	0.72	0.76	0.71	0.72	0.75
片足立ち (左)	0.99	0	0	0.91	0.88	0.88	0.23	0.80	0	0.96	0.80	0.70	0.01	0.65	0.49
片足立ち (右)	0.99	0.01	0.43	0.41	0.56	0.60	0.88	0.80	0.75	0.71	0.65	0.69	0.58	0.60	0.65
背伸び	0.99	0.44	0.40	0.50	0.47	0.76	0.67	0.81	0.46	0.89	0.84	0.85	0.28	0.89	0.88
重み付平均	0.99	0.17	0.37	0.71	0.74	0.83	0.73	0.86	0.63	0.88	0.81	0.80	0.56	0.79	0.77

表 2 評価実験の被験者情報

	被験者									
	1	2	3	4	5	6	7	8	9	10
身長 [cm]	182	157	173	171	159	170	171	154	170	165
シューズのサイズ [cm]	28	23.5	26	27	24	26	27	23.5	26	25
性別	M	F	M	M	F	M	M	F	M	F

表 3 評価した 22 種類の姿勢および動作

ID	項目	ID	項目
1	直立	12	つま先立ち
2	右足で立つ (片足立ち)	13	しゃがむ
3	左足で立つ	14	右手にかばんをさげて立つ
4	片足加重で立つ右加重, 左も接地	15	左手にかばんをさげて立つ
5	片足加重で立つ左加重, 右も接地	16	右内回りに歩く
6	お辞儀の姿勢で静止	17	左内回りに歩く
7	身体ごと上を見た状態で静止	18	椅子に座る→立ち上がる
8	足は正面スタンス, 顔を右に向ける	19	段の上り下り
9	足は正面スタンス, 顔を左に向ける	20	歩く
10	ふくらはぎのストレッチ (右前)	21	ジョギング
11	ふくらはぎのストレッチ (左前)	22	自転車こぐ

表 4 全エリアの特徴量を用いた被験者ごとの動作認識率

被験者	認識精度 [%]			
	J48	RandomForest	NaiveBayes	SVM
1	99.4	99.9	88.9	99.8
2	98.4	99.3	81.5	99.3
3	99.3	99.9	85.5	99.8
4	99.4	99.9	82.0	99.5
5	99.4	99.9	87.7	99.9
6	98.7	99.6	83.1	99.6
7	90.5	87.9	74.3	91.2
8	98.2	99.5	81.8	98.5
9	98.8	99.8	81.1	99.2
10	98.3	99.5	77.6	99.2
Average	98.0	98.5	82.3	98.6

用いたシステムを想定しており, このインソールの一点は, FSR のセンサの計測点より小さい. そこで, 図 4 に示すように隣接する圧力センサ 4 点ごとの圧力値の平均値を特徴量として用いることとした. 従って, 25cm 以上の被験者の場合, 片足 105 個の計 210 個の特徴量を用い, 25cm 未満の場合, 片足 84 個の計 168 個の特徴量を認識に用いる. 認識アルゴリズムは J48, RandomForest, NaiveBayes, サポートベクターマシーン (SVM) の 4 種類を用い, データマイニングツール Weka[20] を用いて, 3 分割交差検証 (3-fold cross validation) で評価した.

次にどの点が認識精度向上に寄与しているかを算出するため, RandomForest アルゴリズムを用い, 各特徴量の重要度 (寄与度) を算出した. 寄与度の計算は決定木を構築する際, 該当変数をモデルから除いた際の, 予測精度の減少値 (MDA: Mean Decrease Accuracy), あるいはジニ係数の減少値 (MDG: Mean Decrease Gini) の 2 種類について算出した. まず図 4 に示す左右 A1 から O5 まで (25cm 未満は A1 から N3 まで) の特徴量を用いて RandomForest で認識精度と各特徴量の寄与度を算出し, 被験者間でどの程度一致するかを評価する. 被験者間で寄与度の高い点がある程度一致していれば, 最も寄与度が高い結果となったエリアのみで認識率を算出する. この際, 得られたセンサデータから特徴量を抽出する. ウィンドウサイズは 10 サンプル (0.1 秒間) とし, ウィンドウは 1 サンプルごとにスライドさせ, 特徴量を算出した.  $n$  個のサンプル  $x_1, x_2, \dots, x_n$  があり, その平均値を  $\bar{X}$  としたとき特徴量に用いた分散値 (標本分散) は次式で求められる.

$$s^2 = \sum_{i=0}^n (x_i - \bar{X})^2 \quad (1)$$

これらをあわせた各エリアの瞬時値と過去 10 サンプルの平均値および分散値の 25cm 以上のシューズサイズで計 630 個, 25cm 未満のシューズサイズで 504 個の特徴量から, RandomForest を用いて寄与度を算出した.

### 5.3 評価実験の結果と考察

表 4 に全エリアの特徴量を用いた被験者ごとの動作認識率を示す. SVM での認識精度が 98.6% となり, 4 つの分類器の中では最大となった. 次いで RandomForest での認識率が 98.5% であった. RandomForest は一般的に過学習が起きづらいアルゴリズムといわれているが, ここまで精度が良かったのは, 1 セットを 3 分割した際に, 学習データとテストデータにほぼ同じ値が存在したからではないかと

表 5 寄与度の最も高い点 L\_A2 のみを用いた認識結果

被験者	F-Measure (L_A2)																						Ave.
	コンテキスト																						
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	
1	0.00	0.18	0.64	0.00	0.00	0.00	0.81	0.93	0.93	0.02	0.80	0.56	1.00	0.98	0.86	0.30	0.24	0.15	0.28	0.54	0.63	0.15	0.45
2	0.00	0.11	0.50	0.00	0.00	0.11	0.76	0.00	0.00	0.92	0.75	0.93	0.00	0.00	0.11	0.30	0.23	0.02	0.20	0.18	0.59	0.01	0.26
3	0.69	0.30	0.55	0.32	0.64	0.68	0.70	0.71	0.82	0.79	0.55	0.61	0.78	0.69	0.84	0.24	0.21	0.30	0.25	0.35	0.53	0.02	0.53
4	0.00	0.00	0.13	0.00	0.00	0.00	0.10	0.00	0.00	0.11	0.05	0.75	0.98	0.00	0.08	0.14	0.23	0.09	0.29	0.37	0.55	0.28	0.19
5	0.00	0.00	0.71	0.14	0.03	0.63	0.57	0.00	0.00	0.95	0.36	0.46	0.00	0.01	0.04	0.15	0.17	0.06	0.29	0.42	0.57	0.38	0.27
6	0.97	0.00	0.62	0.16	0.20	0.90	0.53	0.95	0.00	0.79	0.28	0.82	0.18	0.96	0.93	0.29	0.19	0.30	0.20	0.21	0.59	0.00	0.46
7	0.20	0.00	0.00	0.00	0.79	0.00	0.62	0.38	0.24	0.96	0.53	0.54	0.69	0.39	0.77	0.29	0.27	0.34	0.33	0.19	0.46	0.46	0.39
8	0.65	0.00	0.39	0.00	0.00	0.15	0.69	0.70	0.00	0.95	0.08	0.56	0.88	0.51	0.22	0.13	0.17	0.02	0.12	0.38	0.44	0.00	0.32
9	0.67	0.00	0.73	0.00	0.00	0.00	0.61	0.00	0.59	0.41	0.60	0.46	0.74	0.00	0.00	0.16	0.19	0.14	0.19	0.15	0.49	0.02	0.28
10	0.68	0.39	0.68	0.27	0.75	0.51	0.67	0.46	0.52	0.78	0.43	0.31	0.68	0.56	0.70	0.24	0.27	0.30	0.27	0.30	0.45	0.65	0.49
Ave.	0.39	0.10	0.50	0.09	0.24	0.30	0.61	0.41	0.31	0.67	0.44	0.60	0.59	0.41	0.45	0.22	0.22	0.17	0.24	0.31	0.53	0.20	0.36

表 6 寄与度の上位 2 点 (L\_A2, R\_A2) を用いた認識結果

被験者	F-Measure (L_A2, R_A2)																						Ave.
	コンテキスト																						
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	
1	0.69	0.30	0.55	0.32	0.64	0.68	0.70	0.71	0.82	0.79	0.55	0.61	0.78	0.69	0.84	0.24	0.21	0.30	0.25	0.35	0.53	0.02	0.53
2	0.00	0.33	0.57	0.00	0.00	0.13	0.82	0.00	0.00	0.94	1.00	0.99	0.01	0.00	0.12	0.41	0.37	0.15	0.36	0.33	0.82	0.00	0.33
3	1.00	0.91	0.87	0.96	0.96	1.00	1.00	1.00	1.00	0.99	0.99	0.96	0.99	0.98	0.99	0.50	0.59	0.92	0.71	0.76	0.90	0.91	0.90
4	0.44	0.69	0.18	0.00	0.00	0.00	0.14	0.00	0.00	0.67	0.05	0.81	0.99	0.54	0.08	0.45	0.35	0.09	0.41	0.77	0.89	0.32	0.36
5	0.17	0.66	0.84	0.81	0.06	0.74	0.85	0.01	0.17	0.97	0.85	0.86	0.17	0.15	0.06	0.40	0.35	0.13	0.43	0.71	0.92	0.63	0.50
6	1.00	0.98	0.77	0.77	1.00	1.00	0.97	1.00	0.76	0.99	0.86	0.97	0.45	1.00	1.00	0.45	0.46	0.50	0.56	0.33	0.84	0.00	0.76
7	0.39	0.03	0.03	0.04	0.92	0.49	0.92	0.55	0.99	0.99	0.96	0.93	0.93	0.89	0.98	0.52	0.58	0.67	0.63	0.45	0.81	0.76	0.67
8	0.68	0.88	0.52	0.00	0.00	0.21	0.98	0.71	0.00	0.99	0.97	0.87	1.00	0.54	0.22	0.26	0.26	0.04	0.24	0.49	0.64	0.00	0.48
9	0.72	0.28	0.74	0.01	0.00	0.00	0.63	0.00	0.64	0.95	0.66	0.60	0.76	0.00	0.17	0.20	0.32	0.16	0.22	0.35	0.75	0.66	0.40
10	1.00	0.85	0.81	0.97	0.97	1.00	0.97	0.98	0.98	0.98	0.97	0.91	0.99	0.99	0.99	0.47	0.48	0.92	0.63	0.68	0.78	0.97	0.88
Ave.	0.61	0.59	0.59	0.39	0.45	0.52	0.80	0.49	0.54	0.92	0.80	0.85	0.71	0.58	0.54	0.39	0.40	0.39	0.44	0.52	0.79	0.43	0.58

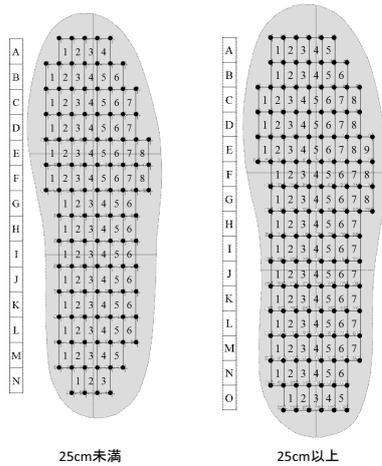


図 4 特徴量として用いる 2x2 マトリクス

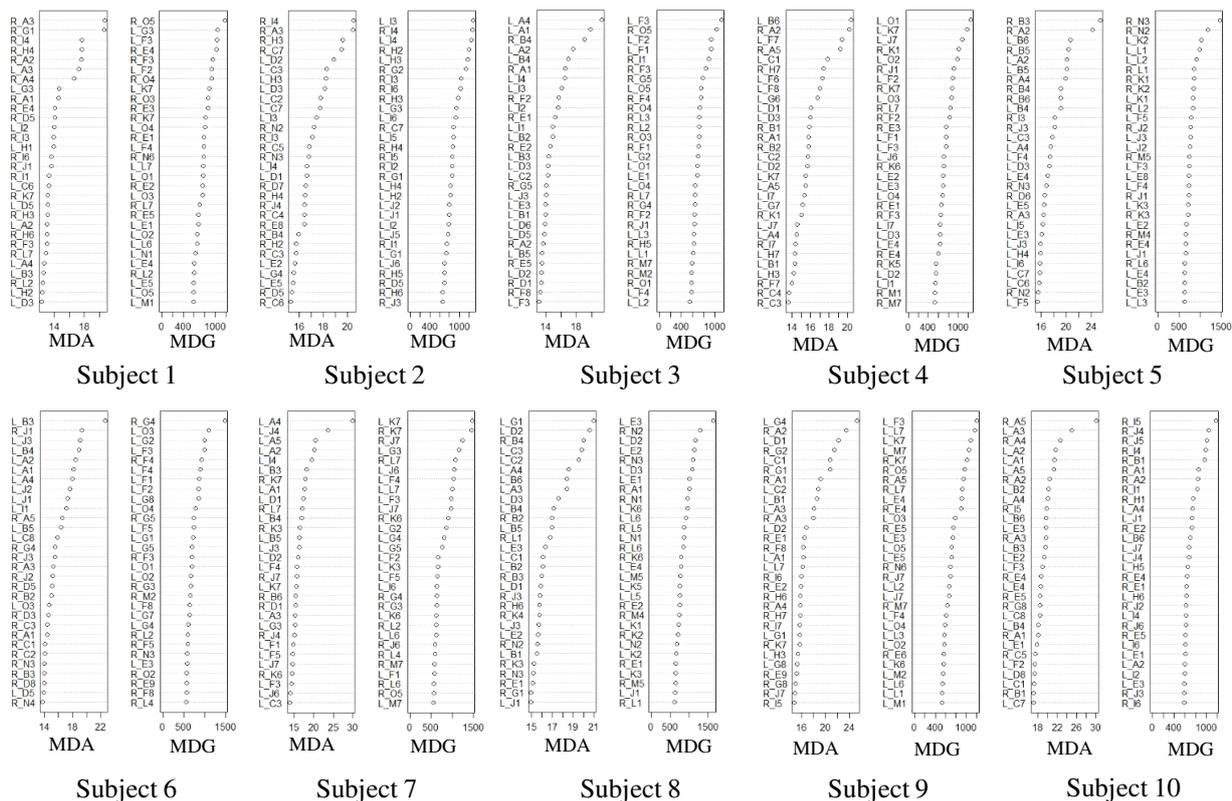
考えられる。この点については、今後実験の試行回数を増やし、評価することが必要である。被験者 7 は、他の被験者と比べ大きく認識率が低かった。図 5 に RandomForest を用いて算出した認識結果を示す。図 5 より、片足立ちがほぼ認識できておらず、これが全体の平均認識率に影響していることがわかる。

寄与度の算出結果を図 6 に示す。MDA と MDG について、その特徴量を用いなかったときの認識率の低下度合いが本研究で求めたい最少構成のセンサ配置を調査するという目的と照らし合わせて、適していると考え、MDA を評価に用いることとした。図 6 のなかで MDA 上位 5 位について、シューズのサイズが 25cm 以上と 25cm 未満とで特徴

Subject 7 (RandomForest)																						F-Measure	
a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	s	t	u	v		
a	0.9865	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
b	0	1.000	0.122	1.681	1.615	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.036
c	0	0.1669	1.22	1.627	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.035
d	0	0.1632	1.667	1.19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.035
e	0	0	0	0.9724	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
f	0	0	0	0	0.8456	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
g	0	0	0	0	0	0.8268	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
h	0	0	0	0	0	0	0.8370	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
i	0	0	0	0	0	0	0	0.4085	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
j	0	0	0	0	0	0	0	0	0.8859	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
k	0	0	0	0	0	0	0	0	0	0.8440	0	0	0	0	0	0	0	0	0	0	0	0	1.000
l	0	0	0	0	0	0	0	0	0	0	0.8502	0	0	0	0	0	0	0	0	0	0	0	1.000
m	0	0	0	0	0	0	0	0	0	0	0	0.4243	0	0	0	0	0	0	0	0	0	0	1.000
n	0	0	0	0	0	0	0	0	0	0	0	0	0.8517	0	0	0	0	0	0	0	0	0	1.000
o	0	0	0	0	0	0	0	0	0	0	0	0	0	0.4503	0	0	0	0	0	0	0	0	1.000
p	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.4623	0	0	0	0	0	0	0	0.988
q	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.4012	0	4	2	0	0	0	0.985
r	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.8580	0	0	0	0	0	1.000
s	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	8	0.3978	0	0	0.988
t	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9	9	0	1.3448	0	0.989
u	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19	0	1	2	0.997
v	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1.000
Ave.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0.875

図 5 被験者 7 の Confusion Matrix

量に用いているエリアの番号が異なるため、分けてプロットしたものが図 7 と図 8 である。図 7 に反映されているシューズサイズが 25cm 以上であった被験者は表 2 より 7 名で、25cm 未満が 3 名である。なお、今回は図 6 より上位 5 位まではある程度寄与度 MDA が高いとみなし、寄与度の順位による重み付けは行っていない。図 7 をみると A2 のエリアが左足で 7 名中 4 名、右足で 7 名中 3 名が寄与度の上位 5 位までに入っている。図 8 をみると D2 エリアのみ 3 名中 2 名が MDA が上位 5 位に入っていることが分かる。これについてはシューズサイズが 25cm 以下の被験者が少なかったため被験者を増やした際の傾向もみるべきと考えた。図 4 のエリアを決める際に、4 点の足圧センサの値の平均をとった値を用いているため、隣接するエリアについては、2 点が重複している。よって、図 7 と図 8 の隣同士が色がついている場合、その間の 2 点が認識精度に寄



MDA: 特徴量加工による重要度(MeanDecreaseAccuracy)  
 MDG: ジニ係数による重要度(MeanDecreaseGini)

図 6 各被験者の特徴量の寄与度

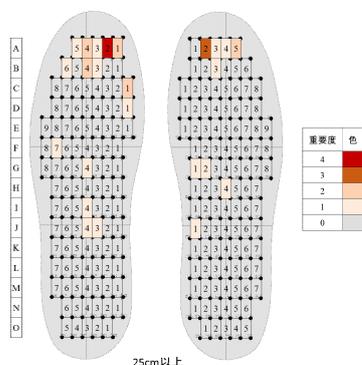


図 7 各特徴量の寄与度上位 5 点 (25cm 以上)

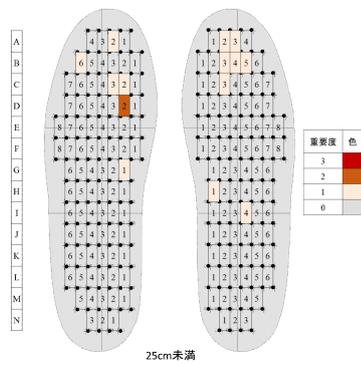


図 8 各特徴量の寄与度上位 5 点 (25cm 未満)

与していると考えられる。図 7 と図 8 から、全体的に足先が寄与度が高くなっており、これは足のかかと付近に比べ足の指があることによって可動域が大きく、体を支える際に足指を使っているからであると考えられる。足先とは対照的にかかと付近ほどの点も寄与度が上位 5 位に入っていない。また、土踏まずがある足裏中央部は認識精度に寄与していないと考えていたが、予想に反し土踏まずの端部分付近が認識精度に寄与している被験者もみられた。これについては扁平足などの詳細な被験者情報をあらかじめ得ていなかったため、今後はそれらの情報を得て確かめる

必要がある。土踏まずがインソールから浮かずに体重を掛けた際に接触していた被験者がいた可能性が考えられ、そのような被験者については、計測点をいくつか設けられるのであれば、土踏まずの端部分にセンサを配置することも考えられる。足先および拇指球付近は寄与度の高い点が多かったため、被験者ごとにセンサ位置を変えることができない環境で、今回のような日常的なコンテキストを認識する場合、計測点を一点にしぼるならこのどちらかが有力ではないかと考えられる。計測したい項目が着地時に関係するような指標の場合などかかとに圧力センサを置くことは

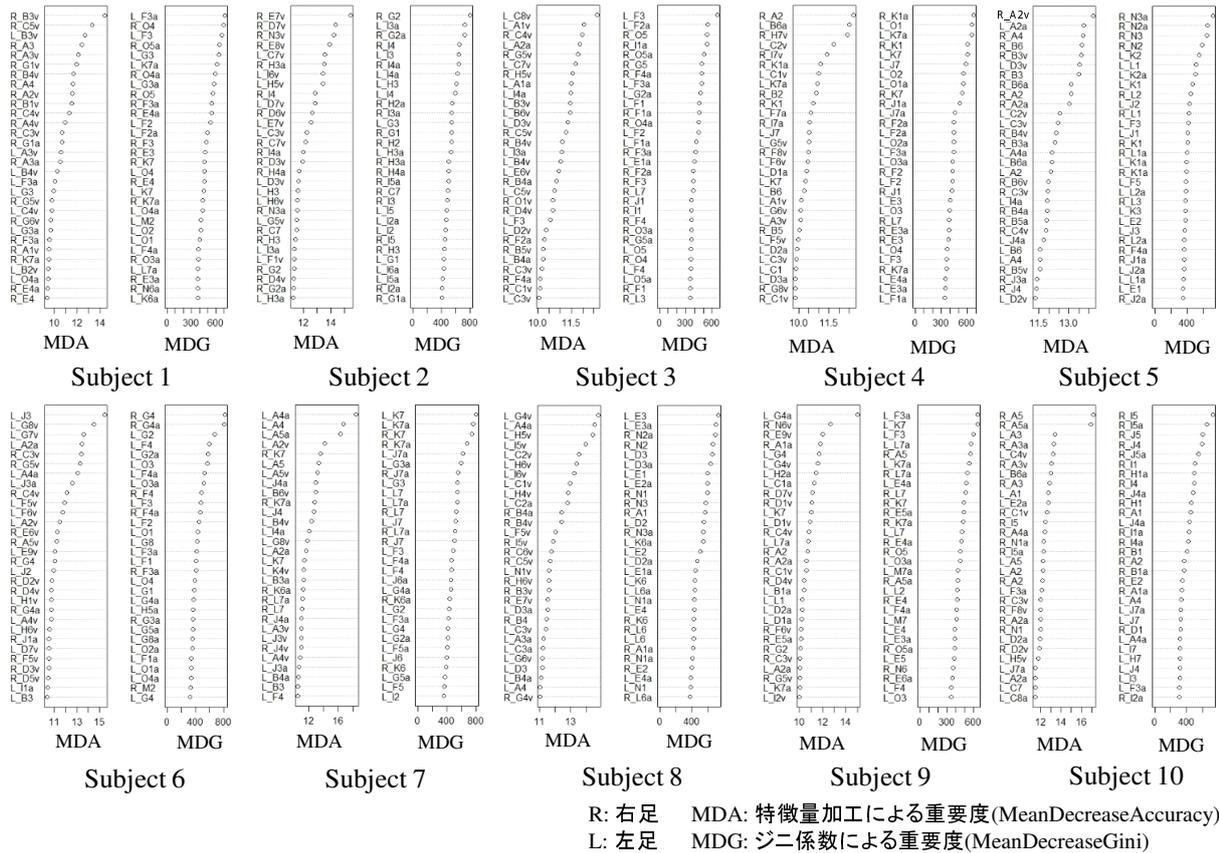


図 9 各被験者の特徴量 630 個の寄与度

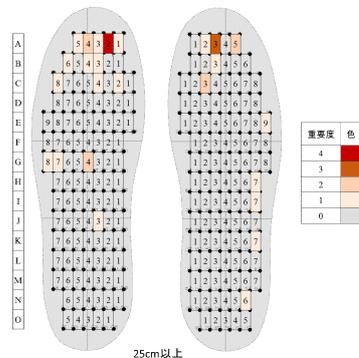


図 10 特徴量 630 個の寄与度上位 5 点 (25cm 以上)

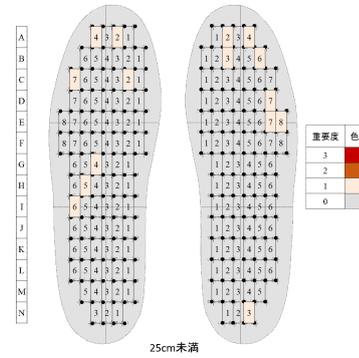


図 11 特徴量 630 個の寄与度上位 5 点 (25cm 未満)

考えられ、このように認識したい項目ごとにセンサ配置を考慮する必要がある。

表 5 は、もっとも寄与度の高かったエリア LA2 のみの瞬時値と過去 10 サンプルの平均値および分散値の 1 つのエリアから得られる 3 つの特徴量を用いて、22 種類のコンテキストを識別した認識結果である。表 6 は、同様の方法で、寄与度の高かった上位 2 点 (LA2, RA2) を用いた場合の認識結果である。表 5 から、最も寄与度の高い 1 点で認識した場合に F 値が最も高くなった被験者で全動作の平均が 0.53 であった。被験者 2, 5, 8 については、シューズサイズが 25cm 未満であったことが原因と考えられる。ま

た、寄与度が最も高い点と寄与度が 2 番目に高かった左右対称な点の 2 点 (片足 1 点ずつ) で認識精度を評価したところ、表 6 のように最も精度の高かった被験者で平均の F 値が 0.90 となった。しかし、シューズサイズが 25cm 以上であっても全コンテキストの平均 F 値が 0.36 となる被験者 4 のような被験者もみられた。これらのことから、それぞれ最も寄与度の高い点を対称にとってセンサを配置した場合、その点の値が特徴的でないユーザの認識精度が極端に低くなってしまふことが考えられる。よって、今後は左右のエリアすべての組み合わせについて認識精度を評価する必要がある。次に、25cm 以上のシューズサイズの被験者

について、片足 105 エリアの瞬時値と過去 10 サンプルの平均値、分散値の計 630 個の特徴量を RandomForest で識別し、寄与度を算出した。寄与度の算出結果をまとめたものを図 9 に示す。MDA が上位 5 位について図 4 にプロットしたものが図 10 と図 11 で、各点の瞬時値、平均値、分散値が上位 5 位に入った場合、それぞれを 1 とカウントし、各点にプロットしている。図 7 では瞬時値のみを特徴量として寄与度を算出していたため、変化の大きな点については上手く判定に使えていない可能性があったが、図 7 と図 10 を比較すると、足先部分が寄与度が高いということは共通しており、図 10 のほうが少し足の外側部分に寄与度の高い点が多くなった。これは、人が様々な姿勢をとるときに足の裏の中心部分はほぼついていっているのに対し、土踏まずがある内側部分はあまり変化がなく、外側のエリアでバランスをとっているせいであると考えられる。これらのことから、足の外側は評価実験で計測した 22 種類のコンテキストをとる際に各動作ごとに規則性をもって変化し、比較的寄与率が高いということがわかった。25cm 未満のシューズサイズの被験者については図 11 では、それぞれ寄与度の高い点は隣接している場合が多いが、一つのエリアが 2 名以上の寄与度上位 5 位に重複して入ることがなかったため、被験者数を増やし考察する必要がある。また、特徴量を 630 個に増やした際も、かかとの内側部分に関しては、寄与度が上位 5 位に入ることは無かった。実験全体を通して、足先付近が寄与度の高い点が多かったため、被験者ごとにセンサ位置を変えられない環境で、今回のような日常的なコンテキストを認識する場合、計測点を一点にしぼるなら足先の点が有力ではないかと考えられる。

## 6. アプリケーション

提案手法の足圧分析の応用例として、足圧値に応じてリアルタイムに光り方が変化するシューズ型デバイス Pressure Lightning Shoes(PL-Shoes) を実装した。図 12 のように片足 3 点に圧力センサ FSR-402 を配置し、その 3 点の圧力センサ値から光の RGB をそれぞれ 256 段階で制御して Arduino Nano に値を送信し、リアルタイムに足圧分布と圧力値の大きさを光で表現する。今後は本論文の評価実験で取得した 22 種類の姿勢および動作のなかからピックアップして、姿勢認識により光のパターンを変えていく予定である。

## 7. まとめ

本論文では、シューズの中に搭載した足圧分布センサを用いて足裏圧力から姿勢や動作の推定を行なった。22 種類の姿勢や動作について J48, RandomForest, NaiveBayes, サポートベクターマシーン (SVM) の 4 種類の分類器で認識精度を評価し、RandomForest で 25cm 以上のシューズサイズの被験者は片足 105 エリア、25cm 未満の被験者は片

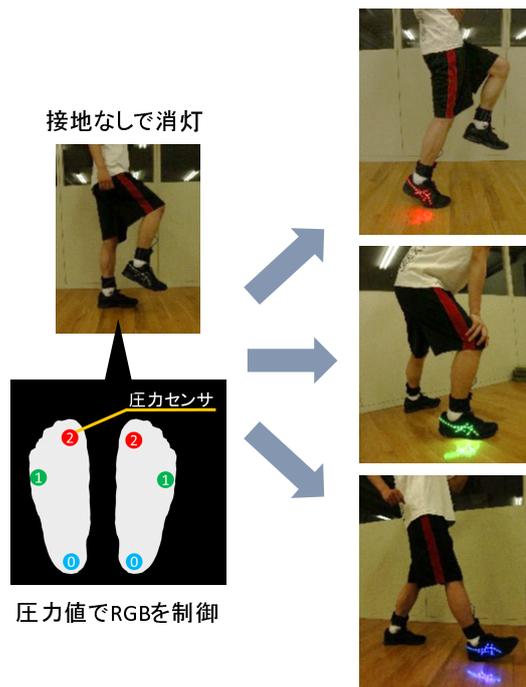


図 12 Pressure Lightning Shoes(PL-Shoes)

足 84 エリアの特徴量の寄与度を算出した。さらに、寄与度の高かった点について認識率を評価することで、最適な計測点を検討した。最も寄与度の高い 1 点で認識した場合に F 値が最も高くなった被験者で全動作の平均が 0.53 であった。また、寄与度が最も高い点と寄与度が 2 番目に高かった左右対称な点の 2 点 (片足 1 点ずつ) で認識精度を評価したところ、最も精度の高かった被験者で平均の F 値が 0.90 となった。しかし、シューズサイズが 25cm 以上であっても全コンテキストの平均 F 値が 0.36 となる被験者もみられた。これらのことから、それぞれ最も寄与度の高い点を対称にとってセンサを配置した場合、その点の値が特徴的でないユーザの認識精度が極端に低くなってしまふことが評価実験より分かった。よって、今後は左右のエリアすべての組み合わせについて認識精度を評価する必要がある。足圧を用いたアプリケーション例として、足圧分布をリアルタイムに光で提示する PressureLightningShoes(PL-Shoes) を実装した。今後の課題として、被験者を増やし、他の計測項目についても同様の方法で評価を行うこと、さらに多くのセンサの位置の組み合わせを総当たりに試すことなどが挙げられる。また、特徴量を 630 個に増やした際も、かかと部分、特にかかとの内側部分に関しては、寄与度が上位 5 位に入ることは無かったため、実験全体を通して、足先付近が寄与度の高い点が多く、被験者ごとにセンサ位置を変えられない環境で、今回のような日常的なコンテキストを認識する場合、計測点を一点にしぼるのであれば足先の点が有力ではないかと考えられる。

謝辞 本研究の一部は、科学技術振興機構 A-STEP によ

るものである。ここに記して謝意を表す。

## 参考文献

- [1] 神野伊策: 圧電 MEMS の基礎技術と応用展開, 応用物理 Vol. 85, No.3, pp. 207–211 (2016).
- [2] B. Zhou, M. Singh, S. Doda, M. Yildirim, J. Cheng, and P. Lukowicz: The Carpet Knows: Identifying People in a Smart Environment from a Single Step, *Proc. of The First International Workshop on Pervasive Smart Living Spaces 2017 (PerLS2017)*, pp. 527–532 (Mar. 2017).
- [3] M. Sousa, A. Techmer, A. Steinhage, C. Lauterbach and P. Lukowicz: Human tracking and identification using a sensitive floor and wearable accelerometers, *Proc. of the 2013 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pp. 166–171 (Mar. 2013).
- [4] 那須圭馬, 金 主賢, 中島一樹: ドア開け時の足下荷重変化と足圧中心軌跡による個人識別法の開発, 計測自動制御学会論文集, Vol. 50, No. 8, pp. 575–579 (2014).
- [5] 中澤昌美, 池田和史, 服部 元, 滝嶋康弘: フロアセンサを利用した屋内行動推定の一検討, 情報科学技術フォーラム講演論文集, Vol. 12, No. 4, pp. 321–322 (2013).
- [6] T. Starner, J. Auxier, D. Ashbrook, and M. Gandy: The Gesture Pendant: A Self-illuminating, Wearable, Infrared Computer Vision System for Home Automation Control and Medical Monitoring, *Proc. of the 4th International Symposium on Wearable Computers (ISWC2000)*, pp. 87–94 (Oct. 2000).
- [7] K. Tsubaki, T. Terada, and M. Tsukamoto: An Activity Recognition Method by Measuring Circumference of Body Parts, *Proc. of the 7th Augmented Human International Conference (AH2016)*, pp. 13:1–13:7 (Feb. 2016).
- [8] K. Murao, T. Terada, A. Yano, and R. Matsukura: Evaluating Sensor Placement and Gesture Selection for Mobile Devices, *Journal of Human Interface Society*, Vol. 15, No. 3, pp. 281–292 (Aug. 2013).
- [9] H. Watanabe, T. Terada, and M. Tsukamoto: Ultrasound-based Movement Sensing, Gesture-, and Context-recognition, *Proc. of the 17th International Symposium on Wearable Computers (ISWC2013)*, pp. 57–64 (Sep. 2013).
- [10] Microsoft: Kinect for Windows, 入手先 <https://developer.microsoft.com/ja-jp/windows/kinect>.
- [11] 大橋勇介, 榎堀 優, 間瀬健二: 足圧布センサを用いた路面形状判別の検討, 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2013, No. 15, pp. 1–6 (2013).
- [12] 深堀孔明, 坂本大介, 五十嵐健夫: 靴下型圧力センサを用いた足裏ジェスチャ, コンピュータソフトウェア, Vol. 33, No. 2, pp. 116–124 (2016).
- [13] K. Hayama and H. Fukuda: Estimation of Center of Pressure Trajectory Using an Insole-Type Force Sensor, *Transactions of Japanese Society for Medical and Biological Engineering*, Vol. 54, No. 1, pp. 15–21 (2016).
- [14] 堀江直正, 満田 隆, 川村貞夫: 足圧情報による歩行状態の推定法, 生体医工学, Vol. 44, No. 4, pp. 621–627 (2006).
- [15] B. Zhou, M. Wirth, C. Martindale, H. Koerger, C. Zwick, H. Cruz, B. Eskofier, and P. Lukowicz: Smart soccer shoe: monitoring foot-ball interaction with shoe integrated textile pressure sensor matrix, *Proc. of the 2016 ACM International Symposium on Wearable Computers (ISWC2016)*, pp. 64–71 (Sep. 2016).
- [16] G. Talavera, J. Garcia, J. Rosevall, C. Rusu, C. Carenas, F. Breuil, E. Reixach, H. Arndt, S. Burkard, R. Harte, L. Glynn, and J. Carrabina: Fully-Wireless Sensor Insole as Non-invasive Tool for Collecting Gait Data and Analyzing Fall Risk, *Proc. of Ambient Intelligence for Health (AmIHealth2015)*, pp. 64–71 (Sep. 2016).
- [17] 杉本千佳, 尾崎賢司, 江副亮介, 保坂 寛, 大和裕幸: 足圧計測シューズによる行動認識, マイクロメカトロニクス, Vol. 53, pp. 24–32 (Dec. 2009).
- [18] medilogic: medilogic Foot Pressure Measurement System, 入手先 (<http://www.medilogic.com/>).
- [19] INTERLINK ELECTRONICS: FSR 402, 入手先 (<http://www.interlinkelectronics.com/FSR402.php>).
- [20] Weka: 入手先 (<http://www.cs.waikato.ac.nz/ml/weka/>).