

シート型圧力センサを用いた洗面台前生活行動識別の試み

園田 謙人¹ 平井 重行²

概要: 洗面台で日常的に行う行動(洗顔・手洗い・歯磨き)には、手腕の往復運動が含まれており、その振動が身体を伝達して床面で計測できることが確認できている。これまで、我々はヘルスメータ型で4隅での圧力計測によってその行動や細かな動作、また個人が識別できることを示してきた。ただ、そのヘルスメータ型の計測方式では、立ち方や位置の制約などで実用的ではないと言える。そこで、今回はバスマット等を想定したシート型センサを用いて洗面台前の床面の圧力分布を計測して、同様の識別を試みた。ここではデータ処理としてCNN(Convolutional Neural Network)で機械学習を行い、3種の行動の識別が90%以上の精度で行えることを確認した。本報告では、利用するシート型圧力センサと現時点でのデータ処理方法、識別結果、および今後の方向性について述べる。

1. はじめに

住宅における生活行動をライフログとして記録するための研究[9]や製品の発売が盛んに行われている。ただし、それらの多くがキッチン[6]やリビングルーム[7][8]を対象とするものであり、トイレ[3]や洗面台[4]、浴室[5]などの生活習慣上で毎日欠かさず利用する箇所での行動計測技術や応用システムに関する製品や研究は比較的少ない。

そのような中で、我々は洗面台前での行動計測やその応用について取り組んできている[1],[2]。一方で、カメラ画像を利用した行動識別・推定の研究が盛んな中で、洗面台は浴室前で脱衣場所であることも多く、ユーザのプライバシーや心理的懸念の話から、我々は画像認識技術を用いずに生活行動を計測・応用する手法が重要だと考えている。

このような観点で洗面台前での日常生活行動に着目したところ、歯磨きや洗顔、手洗いなどの行為には手腕の往復運動が含まれていることに気がついた。そして、その振動は身体を伝搬して足裏まで伝わり、床面でその圧力分布や荷重の変動が計測できることを確認した[1]。また、その振動の特徴量を機械学習技術と組み合わせることで個人推定や行動識別なども試みてきた[2]。これは、将来的なスマートハウス環境では、バスマットが圧力センサを内蔵していたり、床面に圧力センサなどが埋め込まれた環境となって、様々な応用システムへ繋がることを想定している。特に今後のスマートハウス環境では、洗面台の鏡がミラー型ディスプレイの機能を持つことが想定できる。そのような環境では、行動識別やその細かな身体動作の計測データを用い

た生活支援や、より楽しく生活行動を行えるようなインタラクティブなシステムへの応用も期待できる。

本研究では、洗面台前の床面で圧力分布計測を行い、その面状の分布データに対して Convolutional Neural Network (以下 CNN と記載) で行動識別を試みた。今回、我々はシート型圧力センサを用いて、洗面台前生活行動のデータ収集を改めて行うと共に、CNN で学習モデルを作成し行動識別を行った。本稿では、用いたシート型圧力センサと収集したデータについて説明し、CNN の構成や学習および識別結果について述べる。そして今後の課題、方向性を検討する。

2. 日常生活行動による床面荷重変動の計測

2.1 本研究のデータ計測・収録環境

本研究のデータ計測は、京都産業大学内に建築された実験住宅 Home (くすいーほーむ) [13] 内の洗面脱衣室で行った(図1参照)。ここでは、足裏の圧力分布計測にシロク社製のシート型圧力センサ*1 (以下、圧力センサと記載)を用いた(図2参照)。この圧力センサは、480mm 四方の領域において、10mm 間隔でセンサ素子が2次元状に配置されており、センサー一枚あたり 2304 点の圧力分布が計測できる。本研究においては、洗面台前での一般的なバスマット程度の領域で圧力分布を計測できることが望ましいと考え、このシートセンサを横に2枚配置してデータ収集を行うこととした。これは、洗面台へ向かって横方向に 960mm、前後方向に 480mm の領域で計測することとなる(圧力は横方向 96 点、縦方向 48 点、計 4608 点で計測)。

¹ 京都産業大学大学院 先端情報学科

² 京都産業大学 情報理工学部

*1 LL シートセンサ (株式会社シロク製)

<https://www.llsensor.com>

この圧力センサで足裏の圧力分布を計測した例を図3に示す。これにより、圧力センサ上に載せた足の圧力分布や荷重バランスなどが計測できるほか、そのデータの合算からは体重の情報も計算できる。圧力の各計測点は50Hzサンプリングで計測を行い、USB接続されたPCでデータ収集を行った。なお、実際の洗面台前での行動のデータ収集においては、その行動の様子をビデオ撮影し、圧力センサで得られる各データに対して機械学習に用いるラベル付けに用いた。



図1 計測を行った洗面台



図2 シロク社製シート型圧力センサ




図3 足裏の圧力分布計測例

2.2 本研究における行動と動作の定義

本研究においては、洗面台前における日常生活で行う「手洗い」「歯磨き」「顔洗い」などを計測・識別対象としており、本稿ではこれらを「行動」と呼ぶ。また、それら行動の中で行う一つ一つの所作（例えば、手洗い時の石鹸を手を持つ、石鹸を泡立てる、手についた泡をすすぐ、など）を「動作」と呼ぶ。

2.3 データ収録とラベル付け

今回は、健康な成人男性3名（いずれも20代）からデータ収集を行なった。圧力センサ前での待機状態から計測開始し、圧力センサ上に乗って、「手洗い」「歯磨き」「顔洗い」のいずれかの行動を行って圧力センサから降りるまでを一試行とし、その間の圧力分布のデータ（4608ch分）をPC上で記録した。各被験者の3つの行動それぞれの収集した回数（試行回数）を表1に示す。

表1 試行回数

—	被験者 A	被験者 B	被験者 C	合計
手洗い	14	12	9	35
歯磨き	13	12	9	34
顔洗い	14	12	9	35
合計	41	36	27	104

次に、各行動別に収録された時系列データに対し、撮影された動画を参考にして動作レベルでのラベル付けを行った。ただし、すべての細かな動作へのラベル付けは困難であるため、「手洗い」行動については手をすり合わせる動き、「顔洗い」行動については顔をこする動き、「歯磨き」行動については磨く場所に注目して、それぞれラベル付けを行った。また、「ノイズ」ラベルには三行動のどれにも当てはまらないようなデータが含まれており、「行動名+その他」ラベルには三行動内の動作ではあるが、ラベルづけにくいようなデータ（動作と動作の遷移途中など）が含まれている。各被験者の行動から得た動作ラベルの付いたフレームの総数を表2に示す。

3. CNNによる識別処理

データ計測後、ラベル付けされたデータの処理手順について述べる。

3.1 CNNに入力するデータセットについて

ラベル付けされたデータは個人毎、ラベル毎にフレーム数が異なっているため、CNNへの入力の際にデータ数の統一を行う。データ数の統一は、最もフレーム数が少ない動作を基準として行動毎のデータ数を決定、各行動内の各動作から均等に無作為抽出を行う。今回は、4500フレームを行動毎のデータ数として決定し、無作為抽出を行い、入力用のデータセットを作成した。また、識別精度の妥当性

表 2 ラベル付けされたフレームの総数

行動名	動作名	被験者 A	被験者 B	被験者 C
	ノイズ	7173	4844	3115
手洗い	水洗い	5254	4014	1757
	石鹸取り	702	905	591
	石鹸把持	12355	6091	4068
	石鹸置き	695	606	555
	泡洗い	20250	22308	13922
	泡ゆすぎ	13880	14635	9648
	水払い	2596	1152	1408
	手拭き	7881	6224	4101
	手洗いその他	2227	2615	2998
歯磨き	ノイズ	36374	44097	31735
	前歯	33275	8947	19308
	右奥歯	40589	26063	30966
	左奥歯	36851	25406	31696
	歯磨きその他	2615	5704	3552
顔洗い	ノイズ	8157	10335	6343
	水顔洗い	9590	5159	6374
	泡立て	5522	2912	3570
	洗顔	17030	23029	16265
	顔洗い	25260	20348	21977
	水払い	1420	1065	1421
	手顔拭き	13379	9554	6072
	顔洗いその他	9668	12904	14630




図 4 今回作成した CNN の構造

4. CNN による識別結果と考察

CNN を用いた識別結果について述べる。本研究は一般家庭内での使用を想定しており、家族一人一人に対して、一から識別モデルを作成することは、データ収集とラベル付け作業の点から、現実的ではないと考えている。ここでは、家族まとめた統合的な識別モデルを作成しておき、計測システムを使用していく中で家族それぞれのモデルに調整していく仕組みが望ましいと考えている。本章の以下の節では、被験者 3 人のデータを元に、行動レベルの識別を行う統合的なモデルを CNN で学習し、その識別性能について示す。そして、その統合モデルとは別に、被験者毎の識別モデルを作成した識別性能についても示す。なお、以下の CNN の学習においてはすべて epoch 数を 50 とした結果である。

を検証、確認するために一般的な交差検証の手段の一つである N 分割交差検証法を用い、N を 5 として 5 分割交差検証を行う。CNN にはラベル付けされたデータの 1 フレームを 48×96 の画像として入力する。学習の際には、教師データの一部をバリデーションセットとして使用する。

3.2 今回使用した CNN の構造について

CNN は、畳み込み層 (Convolution Layer)、プーリング層 (Pooling Layer)、全結合層 (FullyConnected Layer) からなるニューラルネットワークである。今回作成した CNN の構造を図 4 に示す。図中の Conv, Pooling, Full はそれぞれ、畳み込み層、プーリング層、全結合層を表し、数字は隠れ層の何層目であるかを表している。入出力層を含み 7 層構造になっている。はじめに、Conv1 では、入力データとして $48 \times 96 \times 1$ の圧力分布データを与え、 3×3 のフィルターで畳み込みを行うことで、32 枚の特徴量マップを得る。次に、Pooling2 で Conv1 から得た特徴量マップを入力とし、小領域 (今回は 2×2 領域) に対して最大のものを選択するマックスプーリング (Max Pooling) により、圧縮を行う。同様の動作をもう一度 Conv3, Pooling4 と行い、その出力を Full5 に入力し、識別を行う。中間層の活性化関数には relu 関数を用い、出力層の活性化関数には softmax 関数を用いた。最適化手法は adam を用い、学習率は 0.0001 としている。

4.1 被験者 3 人の統合モデルの識別精度

被験者 3 人の統合モデルを用い、個人毎の行動識別を試みた結果、最尤識別率は 93.8% となった。その結果を表 3 に示す。ここでは、5 分割交差検証を行った際の 5 つのモデルそれぞれに対する行動識別性能と、平均値を示している。

図 5 は、個人毎に分けた識別性能を表す混同行列である。そして、図 6 はそれを個人で分けずに統合した結果としての識別性能の混同行列である。

表 3 統合モデルの各モデルの識別結果 [%]

—	被験者 A&B&C
Model.1	93.43
Model.2	93.82
Model.3	93.30
Model.4	93.43
Model.5	93.42
平均	93.48(± 0.18)

4.2 個人毎のモデルでの識別精度

個人毎のモデルを用いて、行動識別を試みた結果を表 4 に示す。ここでは、5 分割交差検証を行った際の 5 つのモデルそれぞれに対する行動識別性能と、平均値を示している。

図 7 は、個人毎のモデルを用いた識別性能を表す混同行列と識別精度である。




図 5 統合モデルの行動別混同行列 (被験者を区別しての表示)

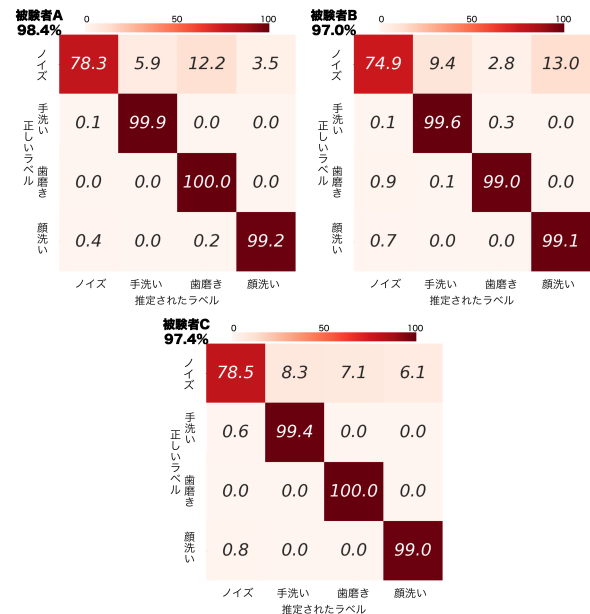


図 7 個人モデルの行動別混同行列
左上) 被験者 A, 右上) 被験者 B, 下) 被験者 C




図 6 統合モデルの行動別混同行列 (被験者をまとめた表示)

表 4 個人毎の各モデルの識別結果 [%]

—	被験者 A	被験者 B	被験者 C
Model_1	97.92	96.36	96.92
Model_2	98.36	96.97	97.44
Model_3	97.83	96.75	97.25
Model_4	95.08	96.36	96.58
Model_5	98.00	96.33	96.89
平均	97.44(± 1.19)	96.55(± 0.26)	97.02(± 0.30)

4.3 識別結果に対する考察

4.3.1 統合モデルに関する考察

図 5 および図 6 の混同行列からは、ラベル「ノイズ」のデータが行動間および個人間を超えて識別誤りが起こっていることが確認できる。その原因については、各行動における圧力センサの上に両足でしっかりと立つ直前や最中のデータも含まれていることによると考えられる。そして、ノイズ以外の 3 つの行動間での識別誤りについては、行動中の一時的な動作が止まったタイミングのデータが、ノイ

ズのデータと似ていることに起因していると考えている。一方で、図 5 においてノイズを除いた 3 つの行動の識別結果で見た場合には、個人および行動を含めた識別は全て 97% 以上であり、個人間の識別誤りは 1% 以下となっている。これは、統合モデルにおいて個人識別と行動識別が同時に高精度で行えることを示している。

4.3.2 個人モデルに関する考察

図 6 の個人毎のモデルにおいても、ノイズが 3 つの行動に渡って識別誤りを引き起こしていることが確認できる。これも、上記の統合モデルと同様の話と考えられる。そして、ノイズを除く 3 つの行動の識別性能に着目すると、どの被験者のデータも 99% 以上の識別が行えている。これは、何かしらの手段で個人特定ができていれば、統合モデルに比べ、より高精度な行動識別が行えることを示している。

5. 今後の課題

5.1 識別すべき人数について

本研究は、一般住宅での日常生活行動の識別やその応用を想定して行っている。識別すべき人数は、居住人数であり少ない場合で 2 人、多い場合で 3 世帯家族などを想定すると 7~8 人と言える。その点を踏まえると、現時点で 3 人の被験者データから学習を行っているのに対し、データ収集する人数を増加させて、ランダムに被験者を選んで人数毎の識別結果を示すべきである。今後はそのためのデータ収集をさらに進める予定である。ただ、個人の動作の違いや、体重、体格、性別、年齢などによる身体の振動伝達特性も関係すると考えられることから、多種多様なデータ収集を行った上での識別性能の検証が必要と言える。

5.2 衣類の違いや体重の日内変動について

同じ人物でも、季節によって衣類の種類や枚数が変わったり、同じ季節でも日によって着る衣類の違いによって、洗顔などの同じ行動でも動作（腕の振り方）などが微妙に違う可能性がある。衣類の重さによって別の人物でも体重が似たものになることや同一人物でも体重の日内変動があることから、それらが識別結果に影響を及ぼす可能性についても調べる必要があると考えている。現在は、被験者のデータ収集時に体重測定を行ってはいないものの、衣類の種類・重さ、体重の日内変動などまでは見てはいないので、それらについても今後の検討課題とする。

5.3 識別する行動の種類について

本報告では、男女や年齢に関わらず、多くの人が日常的に行う共通的な行動として「手洗い」「歯磨き」「顔洗い」の3つの行動を対象としている。ただ、日常生活において洗面台で行われる行動としては、男女や年齢、個人による違いはあれど、化粧（および化粧落とし）や髭剃り、コンタクトレンズの扱いなど、様々な行動・動作がある。それらの行動まで踏まえた識別を行うためには、当然ながらそれらのデータ収集を行う必要がある。現時点の3つの行動については、衛生管理や健康管理に関係する行動という観点から、それらを主に識別することを目指している。

5.4 実際の利用場面を想定したデータ収集について

今回行ったデータ収集は、シート型圧力センサを洗面台前に設置して、その上に直接に人が乗った状態のものである。しかし、実際の生活場面においては、洗面台が水場であることや浴室前であることが多いことから、床にはバスマットが置かれていることが多い。その点を踏まえると、圧力センサの上にバスマットを置いた状態でのデータ収集も行い、バスマットによる圧力分布への影響も調べられる必要がある。なお、現時点で我々が行った予備実験では、薄めのバスマットであれば、バスマットがない状態と同等の圧力分布が計測できることを確認している。今後は、バスマットの厚みや構造による識別性能への影響についても確認を行っていく。

5.5 時系列を考慮した学習について

シート型圧力センサからは、50Hz サンプリングされた圧力分布データを収集しているが、今回のCNNの学習では、データの時系列の連続性は配慮せず、すべて瞬間的な圧力分布を独立したデータとしてラベル付けして学習させている。そのような形で4章で述べた識別性能が出ているものの、実際には時系列性を配慮した処理を行うことで、より識別性能は高まることが考えられる。今後は、時系列データとして処理するCNNの構成、およびデータセット作成を行い、識別性能の違いについて確認をする必要がある。

5.6 動作レベルでのCNN識別について

本報告では、行動レベルでの識別処理について述べたが、同じ行動内でもよりプリミティブな動作レベルについても同様の手法で識別処理が行える。2.3節で述べた通り、動作レベルでのラベル付けは行えているので、CNNでの学習と識別を試みることができる。行動レベルでの識別に比べ識別対象数が増えるものの、洗顔時の石鹸の利用回数や、歯磨き時の奥歯のブラッシングの時間長などの詳細情報が取得できる可能性がある。これは、衛生管理や健康管理のためのより有益な情報として活用できるため、今後は動作レベルの識別も試みていく。

6. おわりに

本研究は、ライフログ活用やインタラクティブな生活行動支援などを念頭において、洗面台前の日常生活行動を非拘束で計測・識別できる手法について取り組んでいる。

そこでは、「歯磨き」「手洗い」「顔洗い」の3つの行動に共通して含まれる手腕の往復運動に着目し、その振動が身体を伝達して床面で計測できることも確認できている。本報告では、シート型圧力センサを用いて床面における足裏の圧力分布を計測し、CNNで行動識別を試みた。

その識別結果からは、3名の被験者を統合したモデルによって、個人識別および行動識別を同時に行い、93.8%の識別性能が出ることを確認した。また、個人毎に構築したモデルでは、それぞれの被験者で97.6%の識別ができることも確認した。被験者数やその多様さ、またバスマットなどの実環境利用へ向けた課題などはあるものの、床面での圧力分布計測と機械学習の組合せによって技術的な可能性は十分に示せたと考えている。一方で、片足ずつの重心を求めたり、足の形や足裏の圧力分布特徴を特徴量として利用した手法や応用も考えられる [10][11][12]。今後は時系列処理への改良を含めたそれら課題を踏まえた上で、より実践的な環境や動作レベルでの識別の試み、リアルタイム識別処理、および応用例の提示を行っていくつもりである。

7. 参考文献

参考文献

- [1] 小山貴之 and 平井重行, スマート洗面化粧台へ向けた床面振動計測と行動認識の検討, 情報処理学会研究報告, 2016-HCI-166, 7, 1-5, 2016
- [2] 小山貴之 and 平井重行, 洗面台での日常生活行動の床面振動計測とその振動モニターシステム, 情報処理学会インタラクシオン 2016, 162B, 36, 624-628, 2016
- [3] 倉橋 真也 and 村尾 和哉 and 寺田 努 and 塚本 昌彦, トイレトペーパーの回転に基づくトイレ使用者識別手法, 情報処理学会論文誌, 58, 1, 237-248, 2017
- [4] 吉川昌秀 and 寺田佳代子 and 江口佳記 and 飛田博章, TEALION 洗面台見守りサービスの提案, 情報処理学会研究報告, 2016-CVIM-200, 35, 1-6, 2016
- [5] 大西諒 and 平井重行, RFID を用いた浴室内行動計測の基礎検討, 情報処理学会論文誌, 49, 6, 1932-1941, 2008

- [6] 椎尾 一郎 and 浜田 玲子 and 美馬 のゆり, Kitchen of the Future: コンピュータ強化キッチンとその応用, コンピュータソフトウェア (日本ソフトウェア科学会), 23, 4, 36-46, 2006
- [7] Branzel, Alan, et al., "GravitySpace: tracking users and their poses in a smart room using a pressure-sensing floor", CHI 2013, 725-734, 2013
- [8] 中里祐介 and 神原誠之 and 横矢直和, 不可視マーカを用いた位置・姿勢推定のための環境構築とユーザ位置・姿勢推定システム, 日本バーチャルリアリティ学会論文誌, 13, 2, 257-266, 2008
- [9] 大内一成 and 土井美和子, スマートフォンを用いた生活行動認識技術, 東芝レビュー = Toshiba review / 東芝ビジネス&ライフサービス株式会社 Web&テクニカルサービス事業部 編, 68, 6, 40-43, 2013
- [10] 那須圭馬 and 金主賢 and 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誌, 50, 8, 575-579, 2014
- [11] 武田隆宏 and 倉本圭 and 小橋昌司 and 畑豊, 左右の足底圧力分布の動的変化に基づく生体認証, 日本知能情報ファジィ学会 ファジィシステムシンポジウム講演論文集 27th Fuzzy System Symposium, WH2, 3, 1393-1398, 2011
- [12] 中島一樹 and 水上嘉樹 and 田中幹也 and 田村俊世, 足形を利用した個人識別, 電気学会論文誌 D(産業応用部門誌), 121, 7, 770-776, 2001
- [13] 平井重行 and 上田博唯, 実験住宅 Home (くすいーほーむ)でのユーザエクスペリエンス研究へ向けて, SI2011 講演論文集, 30, 6, 626-634, 2011