

床面荷重分布と時間変動を用いた 洗面台前生活行動認識に関する検討

中本敦也¹ 平井重行²

概要: 洗面台で行われる洗顔・手洗い・歯磨きの生活行動には、手腕の往復運動が含まれ、その振動が身体を伝達して床面で計測可能である。我々はこれまで、洗面台前の床面に設置したシート型圧力分布センサを用いて足裏の荷重分布を圧力画像として計測し、Convolutional Neural Network (CNN) を用いた深層学習による生活行動認識を行ってきた。ただ、これまでは荷重分布の圧力画像を手腕動作に伴う時系列画像としては扱ってこなかった。そこで、今回は時系列処理に Long Short Term Memory (LSTM) を用い、CNN-LSTM による行動認識を試みた。ここでは、3種の行動とそれ以外の状態を含む4クラスに対し、3人分のデータで行動認識を行ったところ、人物と行動の両方を同時認識する統合モデルで85%以上、特定人物の行動だけを認識する個人モデルで97%の認識精度であることを確認した。本報告では、用いた圧力センサと荷重分布を含む圧力画像データ、CNN-LSTMの構成や学習結果、今後の課題について述べる。

1. はじめに

住宅内での生活行動を認識して応用するための数々の研究が行われている。またカメラ画像認識や音声認識の技術を応用した様々な製品・サービスのリリースが相次いでいる。ただ、トイレや洗面台、浴室などの場所は脱衣する場所であり、プライバシーの観点からカメラ設置が難しく、カメラを用いない行動計測や認識の技術が求められる [1][2][3]。我々は、洗面台における洗顔、手洗い、歯磨きなどの日常生活行動には手腕の往復運動が多く含まれることに着目し、床面設置センサでその行動認識を行う事に取り組んできている。当初はヘルスマーター型の四隅の歪みゲージが付いた板状センサを用いて、足裏にかかる荷重の重心を計測し、その時系列信号を Support Vector Machine (SVM) によって85%程度の精度で人と行動を同時に認識できることを確認した [4][5]。また、シート型圧力分布センサを用いて足裏の荷重分布を圧力画像として取得し、Convolutional Neural Network (CNN) による深層学習での認識も試みた [6][7]。ここでは3人分のデータとはいえ、人と行動の同時の認識が90%以上の精度で行えている。ただし、本来は手腕の振りの運動が足裏荷重の重心の時間変動として反映されるところ、このCNNによる荷

重分布画像認識では、画像を時系列情報として学習に使っていなかった。これは、足裏の荷重分布情報だけで、人の足のサイズや体重の情報が含まれており、人物の認識に有効であること、また同じ人物であっても、洗面台での生活行動毎に足の位置や荷重分布が違うことを示唆している。

本研究は、この床面の荷重分布画像の深層学習において、時間変動も取り入れることで認識率を向上させ、より実用的な技術として確立することを目的としている。今回は、時系列データの学習に有用な Long Short Term Memory (LSTM) を採用し、CNN-LSTMの構成による深層学習を試みた。本報告では、用いたシート型圧力分布センサと学習に用いたデータについて説明し、CNN-LSTMの構成と学習および認識結果について述べる。そして、それら結果を踏まえた今後の課題についても述べる。なお、本研究では、床面圧力分布センサによる行動認識技術が実用化される際には、バスマットに圧力センサ機能が内蔵されるか、バスマットの下にシート型センサを敷いて利用することを想定している。

2. 床面荷重分布画像とラベルについて

2.1 データ計測・収録環境

本研究において、深層学習に用いる圧力画像データの収集は、京都産業大学内に建築された実験住宅E Home（くすいーほーむ）内の洗面脱衣室にて行った（図1参照）。足裏の荷重分布の計測にはシロク社製のシート型圧力セン

¹ 京都産業大学大学院 先端情報学研究科
Graduate School of Frontier Informatics, Kyoto Sangyo University

² 京都産業大学 情報理工学部
Faculty of Information Science and Engineering, Kyoto Sangyo University

サ*1（以下、圧力センサと記載）を用いた。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1枚あたり縦48点×横48点の計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く、この圧力センサを洗面台前の床へ2枚を横に並べて配置し、横960mm、前後480mmの領域で計測した（圧力の計測点は横96点×縦48点、計4608点）。各計測点は50Hzサンプリングで計測され、USB接続されたPCでそれら計測データが受信できる。この圧力センサと足裏の荷重分布を計測した画像例を図2に示す。



図1 データ収集に用いた洗面化粧台




図2 床面の圧力センサ配置（上）と計測した足裏荷重分布の例（下）

2.2 洗面台前の生活行動と動作の定義

本研究では、洗面台前における日常生活で行う「手洗い」「歯磨き」「顔洗い」の3つの生活行為を主な計測・認識対象としている。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。今回の深層学習では「行動」レベルでの認識処理を対象としているため、以降の説明では「動作」の認識処理については触れない。

*1 LL シートセンサ（株式会社シロク製）<https://www.llsensor.com>

2.3 データ収集とラベル付け

本報告で用いたデータは、園田らの先行研究 [7] と同じデータセットを用いた。このデータは、健康な成人男性 A, B, C の3名（いずれも20代）による行動データである。具体的には、圧力センサ前での立位待機状態から計測し始め、圧力センサ上に乗ってから「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、その間の荷重分布のデータ（4608点分の各時系列データ）をすべてPC上で記録した。3人による3種類の行動それぞれの収集回数（試行回数）を表1に示す。

表1 収集された行動データの試行数

	A	B	C	計
手洗い	56	30	27	113
歯磨き	45	30	26	101
顔洗い	56	27	26	109
計	157	87	79	323

各行動別に収録された時系列の圧力画像データに対しては、実際に各行動を行っている区間のデータに「手洗い」「歯磨き」「顔洗い」のラベル付けを行った。また、それら行動の区間にあたらない圧力画像の区間には「ノイズ」ラベルを付与した。ここでは、シートセンサに足を乗せる前から、両足を乗せていく過程、両足が乗った後に生活行動を行う前までの区間や、行動の後にセンサから両足とも降りる過程までの区間がそれにあたる。このアノテーション作業は、データ収集時に撮影した動画と共に ELAN*2を用いて行った。以下の表2に各被験者および各行動の行動データにおける取得できた圧力画像の枚数を示す。

表2 連続して取得した圧力画像枚数

ラベル	A	B	C
手洗い	3254	3138	2728
歯磨き	5617	3465	4180
顔洗い	4507	4417	5926

3. CNN-LSTM と用いる学習データについて

3.1 CNN-LSTM で学習するデータセットについて

収集データはいずれも縦48画素×横96画素の圧力画像であり、50Hzサンプリングでの時系列データでもあることから、50fpsの動画データとみなすことができる。園田らの先行研究 [7] では、時系列を無視してCNNで学習させていたが、今回はLSTMで学習させるため、時系列に沿った特定の時間窓（時間長ぶん）で切り出した圧力画像データ複数枚を1データ（1セット）として扱う。今回は、時間窓（切り出す時間長）を1, 2, 3秒として、すなわち50

*2 ELAN: <https://archive.mpi.nl/tla/elan>

枚, 100 枚, 150 枚, の画像枚数分をそれぞれ 1 データとして切り出す。なお, 学習に際しては, 切り出す時間窓のずらし幅を半窓分ずつずらして切り出して学習させる場合と, 1 窓分ずつずらして切り出して学習させる場合とで試すこととした。これらを比較して試すのは, 各データに重複区間がある場合と, 重複区間がない場合で, 学習モデルに認識性能に差が出るかを確認するためである。

行動ラベルが付与されたデータについては, 人物 A, B, C の個人毎および行動ラベル毎に圧力画像枚数が異なるが, CNN-LSTM で公平に学習させるため, データ数を最小の数ものに合わせるべきと言える。今回の場合, 表 2 に示す, 先行研究と同じデータセットを用いており, そこから 1 秒 (50 枚), 2 秒 (100 枚), 3 秒 (150 枚) それぞれの時間窓でデータを切り出す場合, 3 秒で切り出すデータが一番数が少なくなると言える。そして, 1 窓分ずつずらして切り出す最小のデータ数は, A は 45 個, B は 27 個, C は 26 個となる。一方で, 時間窓を半窓分ずつずらしたデータで学習する場合は, 1 窓分ずつずらすものよりデータ数はそれぞれ約 2 倍の数だけ切り出せる。だが, 1 窓分ずつずらしたデータで学習する場合と比較するため, 今回は窓のずらし方がいずれであっても, 人物 A, B, C それぞれの人の各行動を 26 個ずつのデータを各行動のデータ全体からランダムに選択し, 学習データとして用いることとした。なお, 「ノイズ」のデータについては, 収集してある圧力画像のうち, 行動のラベルが付いていない区間からは 3 秒窓で切り出すデータが少ない。そのため, 各試行データの前もしくは後にセンサ上に足が乗っていない画像 (全画素が 0 の値を持つ画像) を追加するゼロパディング処理を施すことでデータ拡張を行い, 多数あるノイズデータの中から必要数のデータをランダムに選択して揃えることとした。

3.2 統合モデルと個人モデルについて

CNN-LSTM による行動認識モデルを学習するにあたり, 人も行動も同時に認識するモデル (統合モデル) の学習と, 個人それぞれに分けた行動認識モデル (個人モデル) の学習と, 両方の場合について学習を試みる (図 3 参照)。前者は, 人物と行動を同時に認識して出力する学習モデルとなる。これは, 3 種類の行動とノイズの計 4 種のラベルに対して 3 人分のデータをまとめて扱うため, 12 クラス識別を行う 1 つのモデルを学習することとなる。統合モデルの学習および検証に用いるデータ数は計 312 個となる。一方で, 後者は人物の認識を別途行うことを前提に, 特定の人物の認識に特化した行動認識モデルを利用する形となる。これは, 3 種類の行動とノイズによる 4 クラス識別のモデルを, 各人のデータでそれぞれ学習することとなる。ここでは, 前節で説明したデータ数から, 各クラスは 26 個ずつのデータで, 一人の個人モデルの学習および検証には計 104 個のデータを用いることとなる。




図 3 統合モデルと個人モデル

3.3 今回学習した CNN-LSTM の構造について

CNN-LSTM は, 動画像や時系列性を持った画像群に対して使用される機械学習モデルである [8][9]。このモデルは, 畳み込み層 (Convolution Layer), プーリング層 (Pooling Layer), LSTM (Long Short Tern Memory) 層, 全結合層 (FullyConnected Layer) からなるニューラルネットワークである。今回用いた CNN-LSTM の構造を図 4 に示す。図中の Conv, Pooling, LSTM, Full はそれぞれ, 畳み込み層, プーリング層, LSTM 層, 全結合層であり, 数字は隠れ層の何層目かを表している。入力層 (Input) から入力された $48 \times 96 \times$ 時間窓分の圧力画像データに対し, Conv1 にて 3×3 のサイズで畳み込みを行い, 32 枚の特微量マップを得る。その次に Pooling2 で Conv1 から得た特微量マップを小領域 (今回は 2×2 領域) から最大のものを選択するマックスプーリング (Max Pooling) により圧縮処理を行う。同様の操作を Conv3, Pooling4, Conv5, Pooling6 で行う。その後, LSTM にて時系列処理を行った結果から Full の全結合層を通して行動認識を行い, 出力層 (Output) で最終的な計算結果を出力する。最適化手法には adam を用い, 中間層の活性化関数には sigmoid 関数を用い, 出力層の活性化関数には softmax 関数を用いる。




図 4 学習した CNN-LSTM モデルの構造

4. CNN-LSTM による学習と検証

本章では, CNN-LSTM による学習結果について述べる。これに対し, 前章で述べた統合モデルと個人モデルについてそれぞれ学習させた。認識精度の検証については, 各学習に用いるデータ数が少ないものの, 5 分割交差検証を行った結果を以下に示す。なお, 以下の学習はすべて, 学習率を 0.0001, epoch 数を 50 とした結果である。

4.1 3 人分の統合モデル

4.1.1 統合モデルの認識精度について

表 3 に, 各時間窓のサイズ (1 秒, 2 秒, 3 秒, 5 秒) と, 時間軸での窓のずらし幅 (1 窓分と半窓分) の組合せた設

定条件における認識精度を示す。

表 3 統合モデルでの各時間窓と窓ずらし幅の違いによる認識精度

時間窓幅 \ 窓ずらし幅	1 窓分	半窓分
1 秒	84.42 %	87.43 %
2 秒	87.15 %	86.22 %
3 秒	81.78 %	87.32 %
5 秒	76.49 %	85.49 %

この結果からみると、時間窓幅 2 秒時の結果だけ逆の傾向だが、全体としては窓ずらし幅は 1 窓分より半窓分で学習するほうが認識精度が高くなる傾向が伺える。これは、半窓分ずらしのほうが、1 データ中の前半もしくは後半のどちらか半分のデータが、それぞれ別のデータにも含まれることになり、LSTM として時系列中の特定のパターンをより認識しやすく学習されることが考えられる。そうすると、元々の収集した圧力画像を時系列データとして切り出して学習データセットを作成する際に、半分だけでなく、3 分の 1 窓分や 4 分の 1 窓分などのずらし幅で時間窓の画像を切り出して学習するほうが、より精度を高められる可能性がある。

他方、この時系列データとしての切り出しの窓ずらし幅の話は、モデル学習時の精度向上の話であるため、実際にセンサの上で歯磨きや洗顔などの行動認識をリアルタイム処理として行う際の窓ずらし幅をどうすべきかの話ではない点に注意が必要である。実応用時には、時間窓幅がどの程度であるべきかが一番重要であり、ニューラルネットからの出力結果をどの時間間隔で得てアプリケーションに利用するかは別の話である。

次に、時間窓 1 秒、窓ずらし幅半窓分 (0.5 秒) 時の認識精度の結果を表 4 に示す。ここでは、5 分割交差検証を行った際の各検証時の学習済モデル (Model1~Model5) の認識精度と平均値を示す。

表 4 時間窓幅 1 秒、窓ずらし幅半窓分の統合モデルの認識精度

Model.1	89.95 %
Model.2	88.28 %
Model.3	84.18 %
Model.4	89.62 %
Model.5	85.14 %
平均	87.43 %

この表の結果や、これ以外の 5 秒以下の時間窓幅と窓ずらし幅による条件下での個別認識精度をみる限り、大きく外れた認識精度となるモデルはなかった。このことから、各条件下で 5% 程度の認識精度の違いは発生するものの、全体の制度としては妥当なものとして学習ができていていることが伺える。

4.1.2 統合モデルの誤認識について

前節で示した結果のうち、時間窓幅 1 秒、窓ずらし幅が半窓分 (0.5 秒) の条件下でのモデルについて、その混同行列 (12 クラス識別) を図 5 に示す。この図では、行と列のタイトル欄において、赤色が人物 A、黒色が人物 B、緑色が人物 C の行動としてそれぞれの文字色で記載している。




図 5 統合モデルの混同行列

(時間窓幅 1 秒、窓ずらし幅半窓分 0.5 秒)

この混同行列からは、ラベル「ノイズ」のデータが、行動間および個人間で誤認識が起きていることが確認できる。特に目立つのが他人のノイズと誤認識されているものである。具体的には A のノイズの認識率は 71.5% だが、誤認識のうち 6% が B のノイズ、16.7% が C のノイズとなっており、それら以外の誤認識率は計 4.3% しかない。同様に B のノイズでは、誤認識のうち 7.3% が A のノイズ、15.9% が C のノイズである。C のノイズにおいては C の歯磨きへの誤認識が 9.5% と比較的多いが、6% が A のノイズ、6.5% が B のノイズとなっており、やはりノイズ間での誤認識が多いと言える。この原因については、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おり、特定の人物に依存するデータほど特徴が捉えられないことが考えられる。また、ノイズデータについてはゼロパディングによるデータ拡張も行ったため、3 人のノイズデータに共通した部分があることも一因と考えられる。これらの原因を考慮して、ノイズはそもそも人物に依存しないものと考えれば、ノイズは人物を特定しない「ノイズ」ラベルとして独立してデータを用意し、統合モデルとしては、各人物 3 行動ずつと「ノイズ」ラベルのデータとして学習すればよいと推察できる。例えば、3 人の場合は 3 人による 3 行動で計 9 つのラベルとノイズにより、10 クラス識別のデータとして学習することが考えられる。

次に、ノイズ以外の 3 種の行動に関する誤認識について

考察する。まずは、3種の行動がノイズとして誤認識するケースは3人もも起きている。これは、1つの行動内で動作から別の動作へ移行する間に動作を止めたタイミングがあれば、その区間のデータはほぼ静止した状態となる可能性があり、それがノイズデータに似ることが一因と考えられる。一方で、ノイズへの誤認識以外の3種の行動間での誤認識については、一部見られるもののそれらのほとんどが1%未満に収まっている。そして、それらはほぼ同一人物内での誤認識となっている。中には、人物Bの認識結果で手洗いと顔洗いの誤認識が13.3%起っており、比較的誤認識率としては大きい。それ以外は非常に少ない割合と言える。なお、このBの誤認識については、顔洗い時に濡れた手を洗顔用のタオルで拭く動作が、手洗い時にも同様の動作として含まれることが、データ収集時の動画を観察して確認できている。このような個人特有の動作パターンが、洗面台で行う行動でも発生し、誤認識が起りやすくなっていると考えられる。ただ、この統合モデルについては、CNNだけで同様の12クラス識別を行った園田らの先行研究 [7] では93.8%の認識率が出ており、今回のCNN-LSTMでの試みでは認識精度が下がる結果となった。その原因は、先行研究と同じ収録画像から今回の学習データを作成しており、圧力画像を時系列画像として複数画像をまとめて1データとしたことから、データ総数がかなり少なくなったことが挙げられる。具体的には、CNNのみの場合は人物と行動の組合せで一番少ないデータの画像枚数が2700程度だったのに対し、今回は同様の組合せで時系列データとして26個しか得られていない。2桁も少ないデータ数で学習と検証を行っていることから、認識精度が下がっても当然と言える。このことから、今後は時系列データの総数を増やして学習を行い、認識精度の向上について検証する必要がある。

4.2 個人モデル

4.2.1 個人モデルの認識精度について

人物A, B, Cそれぞれのデータを元に学習を行い、それぞれ4クラス識別を行う個人モデルを作成した。各時間窓幅(1秒, 2秒, 3秒)と窓ずらし幅(1窓分, 半窓分)による5分割交差検証を行った平均認識精度を表4.2.1, 4.2.1, 4.2.1に示す。これらから、統合モデルに比べて、個人モデルの精度はいずれも非常に高く95%以上ばかりとなった。しかも時間窓幅2秒に限定してみると、いずれの個人モデルも97.75%以上の精度が出ている。先行研究 [7] と同等以上の性能となった。

また、表8には、5分割交差検証の際の5つのモデルの認識精度とモデル毎の平均値を示す。いずれも認識精度がほぼ98%以上となっており、CNNのみの先行研究に比べて1%程度は向上している。

今回のCNN-LSTMによるモデル作成は、統合モデルと

表5 個人モデルAの認識精度

時間窓幅 \ 窓ずらし幅	1窓分	半窓分
1秒	97.76%	97.76%
2秒	98.13%	98.74%
3秒	98.33%	98.45%

表6 個人モデルBの認識精度

時間窓幅 \ 窓ずらし幅	1窓分	半窓分
1秒	96.65%	97.81%
2秒	97.80%	98.25%
3秒	98.37%	98.45%

表7 個人モデルCの認識精度

時間窓幅 \ 窓ずらし幅	1窓分	半窓分
1秒	98.29%	97.96%
2秒	97.82%	97.69%
3秒	95.13%	97.91%

表8 個人モデルの5分割交差検証時の各モデルの認識精度

	A	B	C
Model.1	98.02%	95.96%	98.84%
Model.2	99.04%	98.93%	97.86%
Model.3	98.88%	97.86%	98.66%
Model.4	99.25%	98.93%	97.77%
Model.5	98.50%	97.98%	98.30%
平均	98.74%	98.45%	98.29%

同様に、CNNのみの先行研究と比べて2桁少ないデータ数で学習したモデルである。それにも関わらず同等以上の精度が出ている。これは、時系列性を考慮した学習により、静止画像のみでの処理に比べて動作とノイズとが区別できていることによると考えられる。

4.2.2 個人モデルの誤認識について

図6に、個人モデル毎の混同行列を示す。いずれの個人モデルでも、いずれのラベルも95%以上の認識率となっており、4クラス識別とはいえ図5の統合モデルの混同行列と比べて、ノイズラベルも含め非常に高い数値が並んでいる。先行研究のCNNのみでの各個人モデルと比較しても、ノイズラベルが80%以下だったのに比べ、今回のCNN-LSTMでは97%以上となっており、平均的な認識精度が先行研究を上回ったのはこれが主な要因だと言える。

誤認識の内訳については、統合モデルほど顕著な値としては出ていないものの、個人モデルでもノイズラベルに関連するものが比較的多くみられる傾向にあり、その点では統合モデルと同様と言える。そして、3行動内の認識率に着目すると、個人モデルBの手洗いが顔洗いに4.8%で誤認識している点が目立つ。これは上述した統合モデルの混同行列の考察と同様であり、同じデータセットで学習し

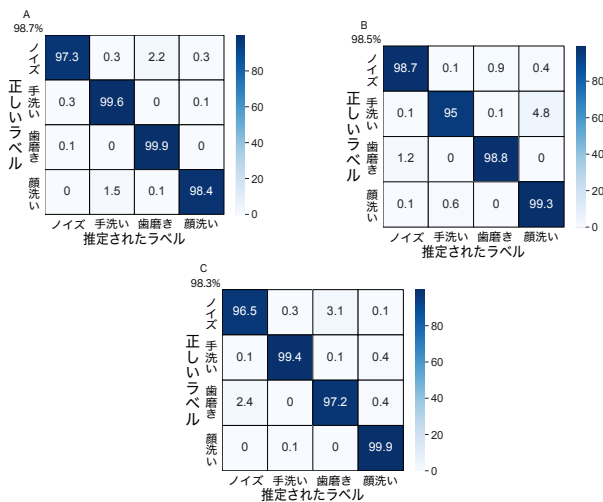


図 6 個人モデルでの各混同行列
 (左上:A, 右上:B, 下:C)

ているために出た結果だと言える。この個人モデル B の箇所と、個人モデル C において歯磨きをノイズとして誤識別している箇所については、先行研究に比べ精度はわずかに下がっているものの、依然として高い認識精度と言える。

これらの結果から、別の手段で個人特定ができれば、統合モデルに比べ個人モデルのほうがより高精度な行動認識が行えることを示している。

5. 今後の課題

5.1 学習データ数について

今回の CNN-LSTM の試みでは、統合モデルの認識精度が先行研究よりも下がる結果となった。これは前述の通り、学習データ数が 2 桁も少ない状況であることに起因していると考えられる。そのため、時系列データとしてのデータ数を増やすべくデータ収集を追加で行う必要がある。また、現時点では 3 人のデータのみで処理を試みているが、実際の家庭を想定すると 5,6 人での認識までできることが望ましい。そのためにも、別の人の行動データを収集していく必要がある。一方で、先行研究でも今回の試みでも、収集した圧力画像データについて、回転処理を施すなどのデータ拡張は行っていない。人が洗面台に立つ際の足の位置や向きは多少揺らぐことは十分に考えられるので、データ拡張も含めて学習データを増やして学習する必要がある。

5.2 時系列処理結果の後処理について

現状のニューラルネットの処理は、入力に対してその都度結果を出力するのみであり、実際の行動を行っているデータを連続的に処理する場合、誤認識が起こると瞬間的に違う行動のデータが出てくることになる。応用のためには、出力結果の時系列性を配慮した認識結果の補正など後処理を行う必要がある。

6. おわりに

本研究は、洗面台における日常生活での歯磨き、顔洗い、手洗いを対象に、床面の圧力分布センサでそれら行動中の足裏荷重分布を計測し、深層学習を用いて行動認識する技術の確立を目指している。本稿では、CNN-LSTM の構成による深層学習を適用し、荷重分布を時系列データとして学習・認識する処理の試みについて述べた。複数人のデータを元に人物と行動を同時に認識する統合モデルと、人物特定された上で行動だけを認識する個人モデルについて、それぞれ学習したうえで認識精度を確認した。現状では、CNN-LSTM のモデルの学習に用いたデータ数が非常に少ないことから、統合モデルでは CNN のみ用いた先行研究に比べ認識精度は下がる結果となった。一方で、個人モデルではデータ数が少なくとも CNN のみと同等以上の認識性能が出ることを確認した。今後はデータ数を増やしつつ、実用的な処理手法として確立すべく研究を進めていきたい。

参考文献

- [1] 大西諒, 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, Vol. 49, No. 6, pp. 1932-1941 (2008)
- [2] 倉橋真也, 村尾和哉, 寺田努, 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, Vol. 58, No. 1, pp. 237-248 (2017)
- [3] 吉川昌秀, 寺田佳代子, 江口佳記, 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, pp.1-6 (2016)
- [4] 小山貴之, 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, pp.1-5 (2016)
- [5] 園田謙人, 小山貴之, 平井重行: 床面振動解析による洗面台前生活行動推定の試み, ヒューマンインタフェースシンポジウム 2018 論文集, 6C1-3 (2018)
- [6] 園田謙人, 平井重行: 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, 情報処理学会研究報告 2018-HCI-180-17/2018-UBI-60-17 (2018)
- [7] 園田謙人, 岡田滉太郎, 平井重行: シート型圧力センサを用いた洗面台前生活行動識別とその応用, 情報処理学会インタラクティブ 2019 論文集, インタラクティブ発表 1B-44 (2019)
- [8] 土井ゆりか, 八木拓真, 水口智仁: CNN-LSTM を用いた手話認識システムの開発, 人工知能学会研究会資料 SIG-AGI-001-06 (2015)
- [9] Ioannis E. Livieris, Emmanuel Pintelas, Panagiotis Pintelas: A CNN-LSTM model for gold price time-series forecasting Neural Computing and Applications (2020)