

推薦論文

RFID タグアレイを利用した非画像信号からの画像復元法と
トイレ行動認識システムへの応用大嶋 政親^{1,a)} 沼尾 雅之^{†1}

受付日 2021年5月5日, 採録日 2021年11月2日

概要: IoT システムを活用した高齢者の見守りシステムを導入することで高齢者の自立を促す効果や介護施設のスタッフの負担を減らすことが可能となる。日常生活行動 (ADL) の中でも、セルフケア動作に関する行動は、高齢者の自立度を測定する指標となるため認識対象としての重要度が高いが、その中でもトイレ動作は複数の動作が組み合わさって完成されるものであるため自動認識は特に難しい。本研究では、パッシブ RFID タグと画像認識技術を組み合わせたプライバシー配慮・デバイスフリーのトイレ行動検知システムを提案する。提案システムでは、人体の姿勢をとらえやすくするために、複数の RFID タグを2次元状に配置したタグアレイを認識対象の背後の壁などに設置する。これにより、アンテナとタグアレイの間にいる人の影画像を RFID タグの信号強度 (RSSI) としてとらえることができる。この非画像信号と本当の画像の間のマッピングを pix2pix によって学習させることによって、タグアレイから得られた非画像信号のみから、画像データを復元することができるようになる。最後に、生成された画像に対して畳み込みニューラルネットワーク (Convolutional Neural Network) を用いた画像分類を行うことで行動を認識する。評価実験として模擬トイレの個室にシステムを設置し、出力画像から CNN を用いて画像分類を行うことで「転倒」を含む 8 種類のトイレ動作を平均正解率 92.18% で分類した。

キーワード: 行動認識, RFID, GAN

Image Recovery from Non-image Signals Using a Passive RFID Tag
Array and Application to Toilet Activity Detection SystemMASACHIKA OSHIMA^{1,a)} MASAYUKI NUMAO^{†1}

Received: May 5, 2021, Accepted: November 2, 2021

Abstract: In recent days, IoT-based watching system for nursing home has been attracting attention because it can reduce the care staffs' workload and also it is used to make a care plan to promote the independence of aged persons. Among the activities that the system recognizes, activities named as Activities of Daily Living (ADL) are important, because it is used to estimate the functional independence measurement (FIM). Among them, toileting activity is especially important but difficult to recognize because it is accomplished in a complex sequence of multiple behaviors, and it is acted in a private room. The image recognition system cannot be used because the camera is not allowed there. In this paper, we propose a device-free toileting activity recognition system using RFID. For this purpose, we propose a two-dimensional tag-array with multiple RFID tags. RFID antenna is placed in front of the tag-array so that the subject's movement is captured as a shadow image on the tag-array. The received signal strength indicator (RSSI) of tags in tag-array is then translated to the real image of the subject by using deep learning technology named pix2pix. In the training phase, we capture the real image by a camera that is placed at the same position as the RFID antenna. The real image is used as a ground truth for pix2pix translation. Finally, the proposed system classifies 8 activities with high accuracy, including fall action of output image using CNN.

Keywords: ADL, RFID, GAN

¹ 電気通信大学大学院情報理工学研究科情報・ネットワーク工学専攻
The University of Electro-Communications, Chofu, Tokyo
182-8585, Japan

^{†1} 現在, 株式会社 OPTiM

^{a)} em49amihso@gmail.com

本論文の内容は 2020 年 6 月のマルチメディア, 分散, 協調とモバイル (DICOMO2020) シンポジウムにて報告され, マルチメディア通信と分散処理研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

1. はじめに

総務省の統計データによると、日本の高齢者人口の割合は世界で最も高く、2025年には65歳以上の高齢者が総人口の3割以上になるとも予測されており [1]、厚生労働省の報道発表資料によると同年に介護人材の需給ギャップは37.7万人に増加すると推計されている [2]。これらの資料から介護スタッフのさらなる負担の増加が懸念される。こうした介護の負担を削減する方法として、IoT技術を活用した高齢者の見守りシステムが提案されている。見守りシステムは、様々なセンサを用いて高齢者の日常行動をモニタリングすることによって、健康管理をしたり、転倒などの異常事態を検知したりする [3]。高齢者の生活する居住空間でモニタリングシステムを構築するためのアプローチは様々あり、ウェアラブルセンサ [4]・カメラ [5]・マットセンサ [6]・ドアセンサ [7]・Radio Frequency Identifier (RFID) と加速度センサを組み合わせたもの [8] などがある。そして、モニタリングシステムが認識対象としているのは高齢者の日常生活行動である。これは、食事・洗面・排泄などの自立的に生活するための最低限の行動であり Activity Daily Living (ADL) と定義されている。これらの ADL に分類される動作は自立度を測定する指標となるため特に重要度が高く、各行動をシステムにより自動で認識することが求められる。ADL の中でもトイレ行動は複数の動作（移動・着脱・排泄・拭き取り）の連続で構成されるため、これらの動作が正しく行われているかは、高齢者の自立度を評価するうえで重要である。一方、トイレ行動はプライバシーが要求される個室で行われるので、介護者による観察は難しく、システムによる自動認識が期待されている分野である。

そこで、本論文では、このトイレ行動をプライバシーを保持しながら自動認識できるシステムを提案する。姿勢認識によく用いられるカメラによる画像認識方法は、個室内にカメラなどを設置することはできないために利用できない。ウェアラブルセンサはデバイスをつねに身に着けないと認識をすることができない。マットセンサ・ドアセンサでは、「入退室」などの情報しか得られずその後の詳細なトイレ動作を認識できない。

これらの問題を解決するために、RFIDを用いた実用的なトイレ行動検知システムの提案を行う。基本原理は、RFIDアンテナとRFIDタグの間の電波伝搬経路の間に障害物が入ることによる受信電波強度 (RSSI) の変動によって、そこにいる人の存在の有無はもとより、その人の姿勢や行動までも認識できるようにすることである。既存方法で多く用いられる対象物や人にタグを装着する方法には、つけ忘れによる認識もれや、装着位置の違いによる認識誤差の問題がある。壁などの環境にタグを設置する既存技術の提案もあるが、複数タグの設置方法や設置位置の違いに

よる認識誤差の問題がある。

こうした課題を解決するためにタグアレイという新しい複数タグの設置方法を提案する。タグアレイの各タグからの RSSI と位相信号を画像データとして扱うことによって、深層学習による画像変換技術である pix2pix を用いて、カメラ画像に変換し、そこからトイレ行動を認識できることを示す。実験評価では実際にトイレ環境を作って、トイレ内で行う8つの動作について学習と認識を行った。(i) タグアレイからの信号をそのまま使って認識器を構成する場合、(ii) タグアレイからの信号からカメラ画像を復元してから認識器を構成する場合、そして、(iii) カメラ画像から認識器を構成する場合を比較した。その結果、(ii) の平均正解率が一番高い 92.18% であることが示された。

本論文の構成は以下のとおりである。2章では RFID による行動認識の既存技術を紹介する。3章では、RFID タグアレイを用いた行動認識手法の提案をする。4章では、行動認識手法の実装方法を示す。5章では、実際にトイレ環境を構築して行った実験と評価について説明する。最後に6章でまとめる。

2. 関連研究

RFIDを用いた既存研究の行動認識システムについて、RFIDタグを人や物などの対象物に設置する場合と、壁や天井などの居住環境に設置する場合について調査した。

2.1 対象物に設置する方法

RFIDタグを人に貼り付けて行動認識システムを構築するメリットとして「誰が」という情報が明らかでありモニタリング、監視の用途に使いやすい。既存研究では、Numaoら [9] が人体に UHF 帯のパッシブ RFID タグを複数枚つけて姿勢の認識を行っている。しかし、認識対象がタグを装着した人物に限られることやウェアラブルセンサと同様につけ忘れが懸念される。

RFIDタグを様々な物に貼り付けるデンスセンシングと呼ばれるアプローチがあり、日常生活で使うコップや皿などのあらゆるものにタグを貼ることで使用判定を行い行動を認識する研究がある [10]。「コーヒーを作る」などの使用判定から推測できる行動については認識できるが、物を介在しない「何もない場所で転ぶ」などの動作を認識することはできない。

2.2 環境に設置する方法

部屋の天井や壁などに RFID タグを貼り付けることでアンテナとタグ間にいる人間の行動認識を行うアプローチがある [11], [12]。また、Oguntalaら [12] が提案したシステムでは、合計で 228 枚の RFID タグを用いて 12 種類のアクティビティに対するクラス分類を行っているが、Yaoら [11] は 8 枚の RFID タグで 12 種類のアクティビティを

分類している。壁は動かないという前提であるため各タグの位置は不変として RSSI や位相の変動から行動認識を行うことが可能である。そのため学習に用いていない人間でも認識結果が期待できるためロバスト性が高いといえる。さらに、ものを介在しない行動についても認識することができる。対象物にタグを貼る方法と比べると『誰が』その行動をしたかは分からないため単純に警報を鳴らすような異常検知には使えるが、居住者 1 人 1 人の健康モニタのようなアプリでは使えない。

2.3 その他の方法

様々なセンサを組み合わせたスマートホームにおいて行動認識システムを構築する研究 [13] がある。Miura らは、複数の部屋の入口にマット型の RFID アンテナを敷き、RFID タグ付きのスリッパを履いた被介護者がどの部屋にいたのか検知するシステムを開発し、ログデータを解析した [6]。Kashimoto らは、Passive Infra Red (PIR) センサとドアセンサを利用して「食べる」「寝る」「掃除」「外出」などの 8 種類のアクティビティをランダムフォレストで分類し F 値は 62.8% となった [7]。さらには、実際にシステムを介護施設に導入してデータを解析する研究もある。井上らは、介護施設のスタッフにスマートフォンや加速度センサなどを持たせ、各部屋に設置している赤外線や温度などの環境センサの情報を収集することでスタッフの行動をセンシングしている [14]。しかし、部屋の入退出を基本にした ADL 認識であり、トイレ内の複雑な行動を認識する方法には用いることができない。

3. タグアレイを用いた行動認識手法の提案

3.1 カメラ画像再現

カメラ画像再現とは、壁に設置した RFID タグの前にいる人物の姿勢をカメラで取得しておき、そのカメラ画像を RFID タグから得られた情報だけで再現するということがある。画像を再現した後は、画像分類を行ってアクティビティを多クラスで分類することや画像から骨格検出につなげることも可能である。これによって、RFID タグからの信号データから特徴量解析・抽出を行う必要はなく、通常画像認識などのタスクにつなげることも可能になる。

3.2 タグアレイ

タグアレイとは、図 1 のように複数の RFID タグを 2 次元状に配置し構成されたものである。タグアレイを周囲に設置する利点として、人体のパーツごとに対応するタグの電波情報を見ることで認識がしやすいということがあげられる。人体の頭部に遮られている場合では上部にあるタグの電波強度が低下しやすく、足に遮られている場合は下部にあるタグの電波強度が低下しやすくなる。それぞれのパーツに割り振られたタグの情報を見ることで学習器が特

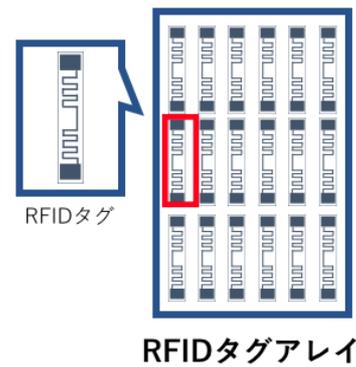


図 1 タグアレイの構成

Fig. 1 Architecture of the tag array.

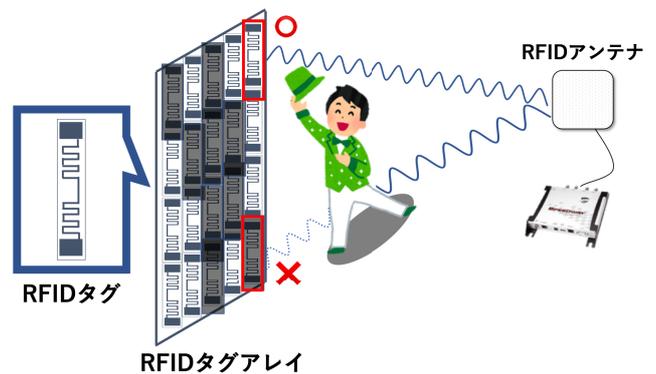


図 2 シルエット検出のイメージ

Fig. 2 Image of human contour acquisition using tag array.

徴をつかみやすくなる効果がある。それらを考慮すると人体の細かい部分に対応するよう横にも縦にも配置されたアレイ状の RFID タグは姿勢認識に適していると考えられる。

図 2 は、タグアレイを使ったシルエット検出のイメージ図となる。アンテナから発された電波が人体に遮られるとタグは読み取れなくなるか、電波強度が低下する。それらのタグを全体的に見ると人体のシルエットのようなものが得られる。タグから読み取れたデータに関しては、前処理を行いグレースケールの画像として扱う。

3.3 RSSI と位相の画像化

RFID リーダーから読み取りを行ったタグアレイの各タグについての RSSI と位相 (Phase) の情報を取得することができる。これらを図 3 のように画像化することで、画像認識技術を適用できるようにする。左側のプロットの 1 つのマスはタグアレイに構成されている 1 枚のタグの RSSI または Phase を示している。ただし、RSSI と Phase を画像に変換するためにはそれぞれ 0–255 の値をとるように変換する必要がある。RSSI は、最小値として -80 [dB]、ある一定の最大値 $RSSI_{max}$ [dB] を定めておき 0–255 の範囲をとるようスケーリングを行う。Phase は、0–360 [deg] の値をとる。0–255 の範囲になるようスケーリングを行

う。また、画像化の際には 256×256 サイズに拡大する。

3.4 タグアレイ画像からのカメラ画像の再現

データセット構築の際には、RFID リーダから各タグの RSSI と位相の情報を取得したと同時にタグアレイの間にいる人物全体を囲うように正解画像を取得しておく。その後、3.3 節の画像化を行い入力画像を生成したあと、入力画像から正解画像を再現する。この処理を経由することによって入力画像から正解画像のような人の姿勢を再現することができる。この処理は画像認識技術である pix2pix を用いて行う。pix2pix とは、Isola らが提案した条件付き敵対的生成ネットワーク (Generative Adversarial Network, GAN) の 1 つであり、線画の着色、モノクロ画像からのカラー画像への変換、地図から航空画像への変換など様々な用途に応じて画像変換を行うものである [15]。図 4 に、条件付き GAN の学習イメージを示す。タグアレイ画像を入力として Generator がカメラ画像のような画像を生成し Discriminator が、本物のペアかどうか判断を行う。Generator と Discriminator を同時に学習させていくことで Generator が生成する画像はカメラ画像に近づいていく。

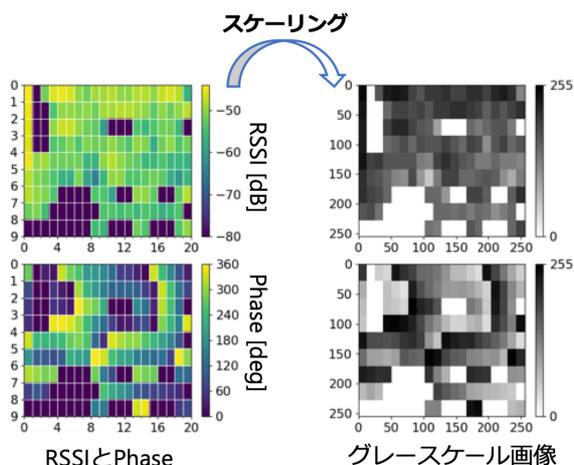


図 3 グレースケール画像化
Fig. 3 Grayscale imaging.

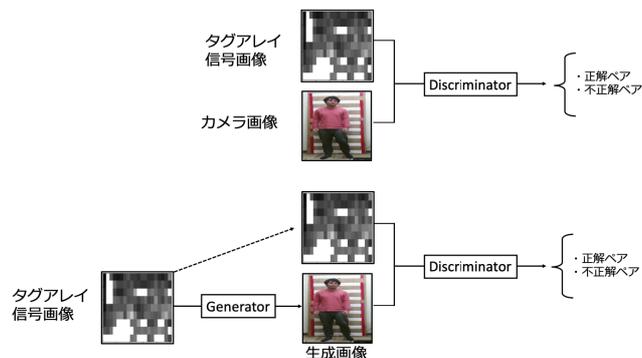


図 4 条件付き GAN の学習イメージ [15]
Fig. 4 Overview of conditional GAN training.

3.5 再現画像からの行動検知

再現画像からの行動認識は、通常のカメラ画像からの姿勢、行動認識技術を用いることができる。ここでは、CNN による画像分類を行うことにより動作分類をすることにする。RFID タグアレイから得られた信号画像を pix2pix による画像生成モデルに入力し、生成結果としてカメラからの RGB 画像のような再現画像を取得する。その再現画像に対して CNN による画像分類を行いアクティビティを認識する。

4. 実装

提案システムは以下の 5 つのプロセスから構成される。モデル構築までの処理は (1) から (4) までで、システム運用中は (5) のプロセスだけで動作する。

- (1) データセット生成
- (2) 画像生成モデルの訓練
- (3) データセットのラベル付け
- (4) 画像分類モデルの訓練
- (5) 画像生成・画像分類による行動予測

4.1 データセット生成

提案システムのデータセット生成までの概要を図 5 に示す。アンテナはタグアレイに含まれている各タグを読み取り RSSI と位相を取得し電波データとして保存する。同時に正解画像を取得するために、Kinect for Windows v2 を設置し、画角内のタグアレイを取めるようにして間にいる人物の姿勢をとらえ保存する。また、使用するアンテナの数によって入力の次元は増減し、今回の実装ではアンテナを 2 個使用したため RSSI と位相のデータでそれぞれタグアレイ縦サイズ \times タグアレイ横サイズ \times 2 の次元となっている。つまり、今回ではアンテナ 1 の RSSI と位相で 2 枚、アンテナ 2 の RSSI と位相で 2 枚、計 4 枚のグレースケール画像を入力として用いる。pix2pix では入力画像と正解画像が対になっている必要があり、作成するデータセットもこれに従う。

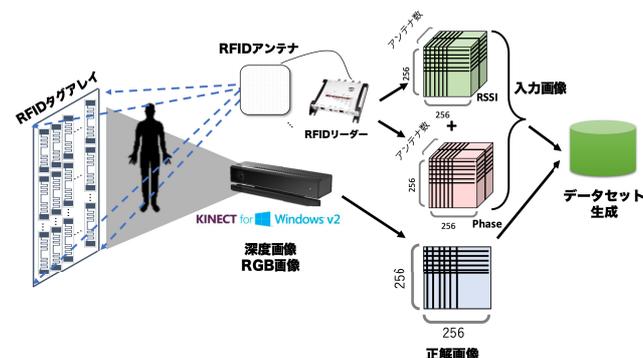


図 5 データセット生成
Fig. 5 Flow of data acquisition.

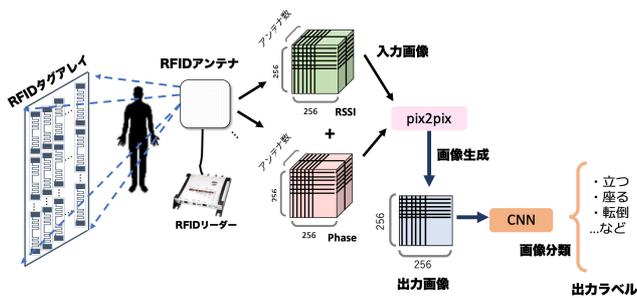


図 6 行動検知の流れ

Fig. 6 Flow of action detection.

4.2 画像生成モデルの訓練

次に作成したデータセットに対して、教師データとテストデータに分割し pix2pix のモデルを GPU (NVIDIA GeForce GTX1080) で訓練した。前節のとおり pix2pix の入力には 4 枚のグレースケール画像を用いるため、これらを 1 枚の画像のように $256 \times 256 \times 4$ の行列に連結し入力とした。pix2pix の実装にあたってフレームワークは PyTorch [16] を用いた。さらに、最適化関数には Adam [17] を用いた。

4.3 データセットのラベル付け

次に、データセットに対して分類したい行動についてラベル付けを行い、ラベル付けデータセットを作成する。すでに生成してあるデータセットを基に新たなラベル付きデータセットを構築するので、データを取得した後からでも分類したいクラスの変更・追加を容易に行うことができる。

4.4 画像分類モデルの訓練

ラベル付けされたデータセットを使用して AlexNet [18] による画像分類モデルを訓練する。このときに使用する教師データは、データセットの入力画像を pix2pix にかけて出力された画像とする。実装にあたってフレームワークには PyTorch を用いた。学習条件として、エポック数は決め打ちで 200 とし Optimizer には SGD [19] を使用した。

4.5 画像生成・画像分類による行動検知

最後に、行動検知までの流れを図 6 に示す。RFID タグアレイから得られた RSSI と位相に対して画像化を行い pix2pix に入力する。その後 pix2pix による画像生成モデルが姿勢画像を出力する。最後に姿勢画像について CNN によって訓練された画像分類器にかけて行動をクラス分類する。

5. 実験

5.1 トイレ姿勢認識

提案手法をトイレ行動に対して適用しラベル付けから行

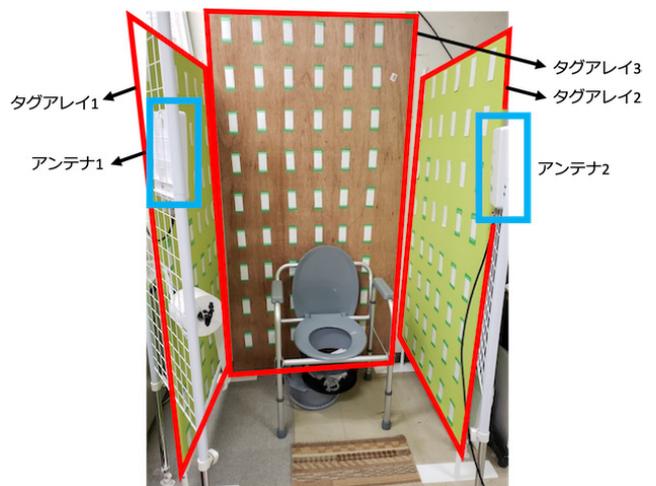


図 7 模擬トイレの外観

Fig. 7 Appearance of a simulated toilet.

動認識まで行う。提案手法の有効性を検証するために画像の再現性評価とクラス分類の評価を行う。認識対象の行動の中には「転倒」クラスも含まれており、異常検出として用いることも可能である。研究室環境に模擬トイレを設置し、被験者 4 人のトイレ行動に関する模擬動作のデータを取得した。

5.2 実験環境

研究室に設置した仮設トイレの様子を図 7 に示す。正解画像取得用として Kinect v2 を使用しており、模擬トイレ全体が Kinect の画角に入るように 1.5m 程度離れて設置している。被験者はこの模擬トイレの中でトイレ動作を行う。仮設トイレは図 7 の赤枠のように、左右のパーティションと奥のベニヤ板の 3 つの壁に囲まれており、それぞれに RFID タグが等間隔に貼られている。RFID タグどうしの間隔は横 10 cm, 縦 8 cm である。RFID タグの総数は 150 枚で、左右のパーティションに 48 枚ずつ奥のベニヤ板の壁に 54 枚貼られている。使用したパッシブ RFID タグは Alien 社の型番 ALN-9770 である。また、アンテナは両サイドに 2 台ずつ設置しており、Yeon Technologies 社の YAP-102CP というモデルである。

5.3 認識行動の定義

認識対象とする行動は図 8 に示す。立つ、座るなどといった基本行動やトイレ特有の行動、そして転倒を含んだ 8 種類の行動を分類する。

5.4 データセット生成

設置した仮設トイレの中で 4 人の被験者が模擬のトイレ動作を行ったときの全 RFID タグからの RSSI と位相データ、正解カメラとして Kinect からの RGB 画像と Depth 画像を取得した。また、全 RFID タグからのデータを取得

表 1 各ラベルの教師データの数と割合

Table 1 Number and percentage of supervised data for each label.

	立つ	衣服の着脱	座る	紙を巻き取る	拭く	流す	転倒	不在
Freq	243	252	152	340	266	401	605	155
Ratio	0.1007	0.1044	0.0630	0.1408	0.1102	0.1661	0.2506	0.0642

表 2 各ラベルの検証データの数と割合

Table 2 Number and percentage of validation data for each label.

	立つ	衣服の着脱	座る	紙を巻き取る	拭く	流す	転倒	不在
Freq	72	75	45	101	79	119	178	46
Ratio	0.1007	0.1049	0.0629	0.1413	0.1105	0.1664	0.2490	0.0643



図 8 認識行動の種類

Fig. 8 Types of toilet behaviors.

するためにかかる時間は 0.5 秒から 1.0 秒程度かかる．そのため 1 分あたり 70 から 80 個程度の全 RFID タグからのデータと RGB 画像のセットが取得できる．なお，データ取得の際には 1 人あたり 5 分 × 3 セットの流れてトイレ動作を行い 5.3 節で定義したような 8 種類のトイレ動作だけでなく，仮設トイレに入ってから退出するまでの一連の流れでデータを取得している．全データ数の内訳は合計で 4,628 個であり教師データが 3,725 個で検証データが 903 個であった．

5.5 画像生成モデルの訓練

これらの全データのうち，教師データを用いて pix2pix による画像生成モデルを作成した．また，検証データに含まれている人物と教師データに含まれている人物は別である．画像生成モデルの作成については，未ラベルのデータも含んだすべてのデータセットを用いて pix2pix を学習した．エポック数は決め打ちで 450 として Optimizer には Adam を使用した．学習係数の初期値は 0.0002 で β_1 は 0.5, β_2 は 0.99 とした．

5.6 データセットのラベル付け

さらに，全データから 5.3 節で定義したトイレ行動に分類するために抽出し正解ラベル付けを行った．全データの

うち，認識対象とする行動にあてはまるものを教師データとしてラベル付けを行いどれにもあてはまらないデータはここで取り除いた．その結果，ラベル付けされた教師データが 2,414 個で検証データが 715 個になった．また，データの各ラベルごとの数と割合を表 1 と表 2 に示す．

5.7 画像の再現性評価

提案システムの画像生成モデルがどのような出力画像を生成するか，そのカメラ画像とどれだけの差異があるか比較を行う．

図 9 は，上からタグアレイからの信号画像と出力画像，そしてカメラ画像になっている．画像生成モデルの教師データにはカメラ画像の人物は含まれていない．そのためカメラ画像の人物は青い服を着ているが出力画像での服装の色は再現されず，姿勢については再現されていることが分かる．左から 4 列目の「紙を巻き取る」の結果を見てみると出力画像でもトイレペーパーに手を伸ばす画像を出力することができている．これは，カメラ画像の人物が紙に手を伸ばしたことによる姿勢の変化を画像生成モデルがとらえることができているということを示唆している．

5.8 画像分類モデルの訓練

ラベル付けされたデータセットを使用して画像分類器を CNN を用いて作成する．ネットワークには AlexNet を用いてエポック数は決め打ちで 200 とした．Optimizer には モーメンタム SGD を使用し，学習係数は 0.001, モーメンタムは 0.9 とした．

5.9 クラス分類実験結果

最終的な行動を認識する画像分類の評価を行う．本提案の有効性を検証するために，分類対象画像として，本提案の pix2pix 生成画像のほかに，タグアレイからの信号画像，そして，カメラ画像の計 3 種類の入力画像から，それぞれ行動ラベル分類の学習を行う．このときの学習用教師データは 5.6 節で説明したものを使い，データ数も同じものにする．3 つの画像それぞれの教師用データから画像分類モデルを訓練した後，それぞれのテスト用データを分類器に

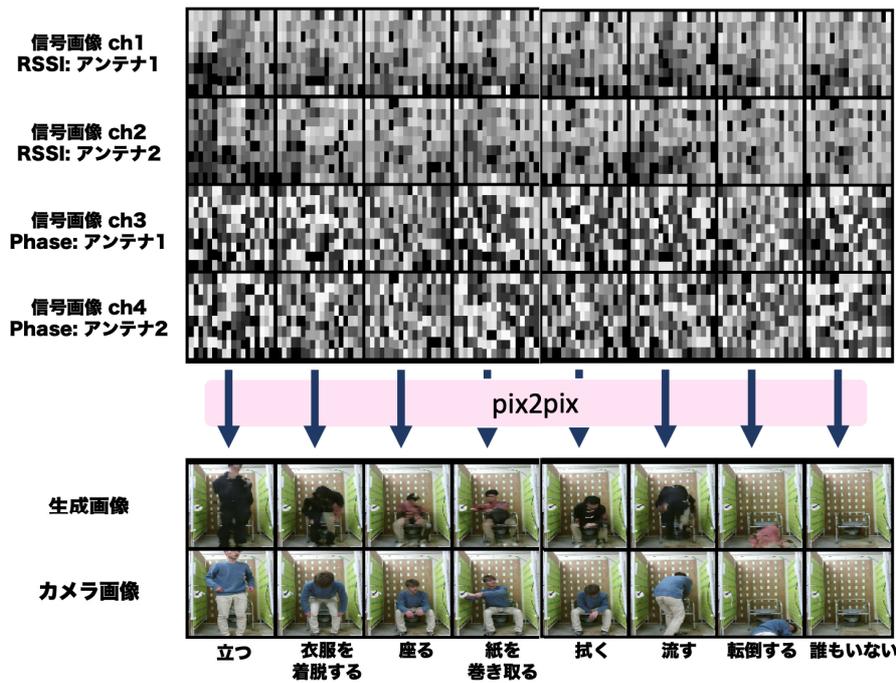


図 9 入力した信号画像と出力された生成画像および実際のカメラ画像

Fig. 9 Input signal images, output generated image, and actual camera image.

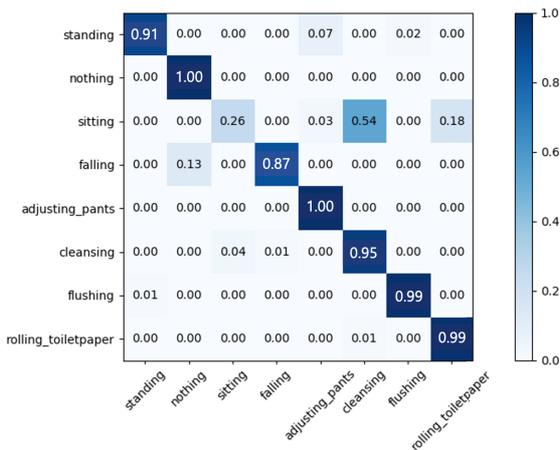


図 10 タグアレイ画像の混同行列平均正解率=90.34%

Fig. 10 Confusion matrix for classification by tag array images.

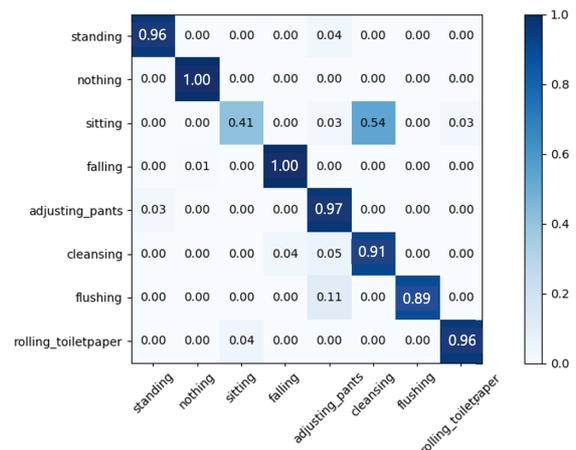


図 11 生成画像の混同行列平均正解率=92.18%

Fig. 11 Confusion matrix for classification by generated images.

かけ正解率を比較する。たとえば、pix2pix が生成した画像の場合では、教師用とテスト用のタグアレイ画像を pix2pix にかけて各々の生成画像を作成し、教師用のデータを用いて画像分類器を学習させた後、テスト用のデータを画像分類器にかけ分類精度を評価するということになる。

タグアレイから得られた信号画像を基に画像分類器を学習し、テストさせた場合の混同行列を図 10 に示す。混同行列を見ると、「座る (sitting)」の分類精度が著しく悪い結果となっており、「拭く (cleansing)」や「紙を巻き取る (rolling toilet paper)」に誤分類してしまっている。これらの行動は便座に座りながら行うものであり、体の大部分の姿勢は変わらず、手の位置が変化する程度のものであ

るため特徴をつかみにくくうまく区別することができないと考えられる。この結果が示すものというのは、言い換えれば RFID タグアレイから得られた RSSI や位相の情報を 3.3 節のように画像化した後は何も手を加えずに分類器にかけた場合の分類精度である。

pix2pix が生成した画像を基に画像分類器を学習し、テストさせた場合の混同行列を図 11 に示す。タグアレイ画像からの認識に比べると転倒の検出率は改善されている。これは転倒がタグアレイでは人物なしと似たパターンになってしまうのが、画像では人がいるパターンとして分類できることによる効果と考えられる。

カメラから取得した画像を基に画像分類器を学習し、テ

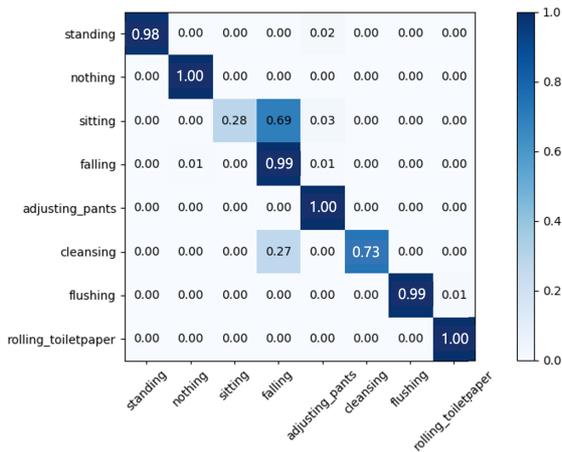


図 12 カメラ画像の混同行列平均正解率=91.87%

Fig. 12 Confusion matrix for classification by camera images.

表 3 分類精度の比較

Table 3 Comparison of classification accuracy.

	平均正解率 [%]
タグアレイ画像	90.34
生成画像	92.18
カメラ画像	91.87

ストさせた場合の混同行列を図 12 に示す。これは通常の画像からの行動認識の結果である。「座る」と「拭く」が、「転倒」に誤分類されている。便座に座るのと、便座の前に倒れ込む姿勢の分類が不十分であることを示している。これは、被験者の服装や体格の違いが影響してしまったものと考えられる。今回は 4 人の被験者の服装と色が異なっていたために、姿勢に対する一般化ができなかったものと考えられる。

タグアレイ画像・生成画像・カメラ画像それぞれでの平均正解率を表 3 に示す。最も高い正解率は pix2pix による生成画像を用いた場合だった。その理由としては、pix2pix の入出力データの対応を学習する過程で、服装や体格の違いなどが吸収されて、タグアレイ画像から人の姿勢を生成するためのコツを画像生成モデルがうまく特徴をつかんだ結果が差として現れていると考える。カメラ画像より生成画像の方が正解率が高くなった理由としては、タグアレイ画像・生成画像・カメラ画像はそれぞれ同じ条件で分類モデルを学習させているが、テストに使われるデータについては学習に用いた人物と別の人物であるため、カメラ画像の場合では服の色の違いなどにうまく対応できなかったものと思われる。一方、生成画像の場合では、服の色の違いは画像生成モデルが吸収し、生成された画像は教師データに用いた人物の色合いで表現されるため分類精度向上に寄与したと推測する。

5.10 考察

トイレ姿勢認識実験は、画像生成モデルの汎化性能やロ

バスト性を活かすために、服装や体格の異なる被験者 4 人によって学習させたことによって、個室内の動作分類に適した方法になっている。本来の目的である高齢者見守りの観点から、この結果を評価すると、トイレ個室での 8 個の基本動作では、座位と拭き取り動作の分類率以外は、実用に耐える精度になっていると考える。ただし、提案手法と比較した 2 つの画像からの分類手法に対する優位性を検証するためには、被験者数を増やす必要があると考えている。

6. おわりに

本研究では、新しく RFID と画像認識技術を組み合わせプライバシーに優しく、かつデバイスフリーなトイレ行動検知システムを提案した。評価実験では、「転倒」を含めた 8 クラスのトイレ行動を定義し 4 人の被験者に研究室環境に設置した模擬トイレで一連のトイレ動作をさせデータの取得をし画像生成モデルの学習を行った。そして、生成画像の再現度の評価と行動クラス分類を行った。画像生成モデルが出力した画像は、学習に用いていない人物のデータであっても姿勢をとらえて再現することを確認した。行動クラス分類の評価では、pix2pix による画像生成モデルが出力した画像を用いた分類の平均正解率が 92.18% と最も高い結果となり、提案手法の有効性を示した。

今後の課題として、データセットの充実による画像生成モデルの誤差のさらなる改善とアンテナの設置位置やタグの配置の変化に影響されにくい頑健なシステムの構築を目指していく。

謝辞 本研究は JSPS 科研費 JP20H04289 「日常生活行動オントロジーに基づく高齢者の自立度評価システム」の助成を受けたものです。

参考文献

- [1] 総務省統計局：高齢者の人口 (2019), 入手先 (<https://www.stat.go.jp/data/topics/topi1211.html>).
- [2] 厚生労働省：2025 年に向けた介護人材にかかる需給推計 (2015), 入手先 (<https://www.mhlw.go.jp/stf/houdou/0000088998.html>).
- [3] Van Kasteren, T.L.M., Englebienne, G. and Kröse, B.J.A.: An activity monitoring system for elderly care using generative and discriminative models, *Personal and Ubiquitous Computing*, Vol.14, No.6, pp.489–498 (2010).
- [4] Mannini, A., Intille, S.S., Rosenberger, M., Sabatini, A.M. and Haskell, W.: Activity recognition using a single accelerometer placed at the wrist or ankle, *Medicine and Science in Sports and Exercise*, Vol.45, No.11, p.2193 (2013).
- [5] Zhang, C. and Tian, Y.: RGB-D Camera-based Daily Living Activity Recognition, *Journal of Computer Vision and Image Processing*, Vol.2, No.12 (2012).
- [6] Miura, M., Ito, S., Takatsuka, R., Sugihara, T. and Kunifuji, S.: An empirical study of an rfid mat sensor system in a group home, *Journal of Networks* (2009).

- [7] Kashimoto, Y., Hata, K., Suwa, H., Fujimoto, M., Arakawa, Y., Shigezumi, T., Komiya, K., Konishi, K. and Yasumoto, K.: Low-cost and device-free activity recognition system with energy harvesting pir and door sensors, *Proc. 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, pp.6–11 (2016).
- [8] Stikic, M., Huynh, T., Van Laerhoven, K. and Schiele, B.: Adl recognition based on the combination of rfid and accelerometer sensing, *2008 2nd International Conference on Pervasive Computing Technologies for Healthcare*, pp.258–263, IEEE (2008).
- [9] Numao, M. and Masuda, S.: Non-restrictive continuous health monitoring by integration of rfid and microwave sensor, *AAAI Spring Symposia, SSS16*, No.7, pp.396–402 (2016).
- [10] Buettner, M., Prasad, R., Philipose, M. and Wetherall, D.: Recognizing daily activities with RFID-based sensors, *ACM International Conference Proceeding Series*, pp.51–60 (2009).
- [11] Yao, L., Sheng, Q.Z., Ruan, W., Gu, T., Li, X., Falkner, N. and Yang, Z.: RF-Care: Device-Free Posture Recognition for Elderly People Using A Passive RFID Tag Array, *Proc. 12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pp.120–129, ACM (2015).
- [12] Oguntala, G.A., Abd-Alhameed, R.A., Ali, N.T., Hu, Y.F., Noras, J.M., Eya, N.N., Elfegani, I. and Rodriguez, J.: SmartWall: Novel RFID-Enabled Ambient Human Activity Recognition Using Machine Learning for Unobtrusive Health Monitoring, *IEEE Access*, Vol.7, pp.68022–68033 (2019).
- [13] Fleury, A., Vacher, M. and Noury, N.: Svm-based multi-modal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results, *IEEE Trans. Information Technology in Biomedicine*, Vol.14, No.2, pp.274–283 (2009).
- [14] 井上創造, 木村幸平, 内野百里, 大屋 誠: 介護施設における介護スタッフの行動センシング実験, Technical Report 13, 九州工業大学, 株式会社 IDC フロンティア (May 2017).
- [15] Isola, P., Zhu, J.Y., Zhou, T. and Efros, A.A.: Image-to-image translation with conditional adversarial networks, *Proc. 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, Vol.2017-January, pp.5967–5976, Institute of Electrical and Electronics Engineers Inc. (Nov. 2017).
- [16] Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Kopf, A., Yang, E., DeVito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J. and Chintala, S.: Pytorch: An imperative style, high-performance deep learning library, *Advances in Neural Information Processing Systems*, Wallach, H., Larochelle, H., Beygelzimer, A., d'Alché-Buc, F., Fox, E. and Garnett, R. (Eds.), Vol.32, pp.8024–8035, Curran Associates, Inc. (2019).
- [17] Kingma, D.P. and Ba, J.: Adam: A method for stochastic optimization. In Yoshua Bengio and Yann LeCun, editors, *3rd International Conference on Learning Representations, ICLR 2015, Conference Track Proceedings* (2015).
- [18] Krizhevsky, A., Sutskever, I. and Hinton, G.E.: Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, Pereira, F., Burges, C.J.C., Bottou, L. and

Weinberger, K.Q. (Eds.), Vol.25, Curran Associates, Inc. (2012).

- [19] Ruder, S.: An overview of gradient descent optimization algorithms, arXiv preprint arXiv:1609.04747 (2016).

推薦文

本論文は介護支援のため、トイレ行動の検知システムを提案している。複数の RFID タグを 2 次元に配置したタグアレイを用い、人体の姿勢をとらえやすくするシステムを提案し、評価において「転倒」を含む 8 種類のトイレ動作を 92% の精度で検出している。高齢化社会に向けて有意義な研究であるとともに、高い精度での動作検出を可能としており、評価委員から高い評価を得た。

(マルチメディア通信と分散処理研究会主査

田上 敦士)



大嶋 政親 (正会員)

1995 年生。2018 年長岡技術科学大学工学部電気電子情報工学課程卒業。2020 年電気通信大学大学院情報理工学研究科情報・ネットワーク工学専攻修士課程修了。同年株式会社 OPTiM 入社。



沼尾 雅之 (正会員)

1981 年東京大学工学部電気工学科卒業。1983 年同大学院工学系研究科電子工学専攻修士課程修了。同年日本アイ・ビー・エム株式会社に入社。東京基礎研究所にてエキスパートシステム、データマイニング、インターネットプロトコル等の研究に従事。2008 年 4 月より電気通信大学電気通信学部教授。現在、同大学院情報理工学研究科情報・通信工学専攻教授。センサネットワーク、RFID 等を利用したトレーサビリティおよびデータマイニングの研究に従事。博士 (情報理工学)。本会シニア会員。