

# パッシブRFIDタグアレイを利用した非画像信号からの画像復元とトイレ行動検知システムへの応用

大嶋 政親<sup>1</sup> 沼尾 雅之<sup>1</sup>

**概要:** センサーネットワーク技術の発達により高齢者の見守りシステムなど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。認識対象の動作の中でも、セルフケア動作に関する行動は被介護者の自立度を測定する指標となるため特に重要度が高く、その中でもトイレ行動は複数の動作が絡み合っているにもかかわらず個室で実行されており、カメラの使用はプライバシーの観点から困難であり認識システムを導入しにくい。本研究では、トイレ行動に着目してパッシブ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、人体の姿勢を捉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。学習データの構築には、RFIDタグから得られたRSSIを画像化する。画像から画像への変換技術の一つであるpix2pixを用いて入力画像と正解画像を対にして学習しモデルを構築することでタグアレイから得られた信号画像のみで人体の姿勢を出力する。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92.18%の精度で分類した。

## Image Recovery from Non-Image Signals Using a Passive RFID Tag Array and Application to Toilet Activity Detection System

MASACHIKA OSHIMA<sup>1</sup> MASAYUKI NUMAO<sup>1</sup>

### 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]。これらの資料から一人あたりの介護スタッフのさらなる負担の増加が懸念される。センサーネットワーク・IoT技術の進歩から介護士の負担を削減する試みとして、様々なセンサーを使用することで被介護者をモニタリングする研究が行われている [3]。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ー [4]・カメラ [5]・

マットセンサー [6]・ドアセンサー [7]・Radio Frequency Identifier (RFID) と加速度センサーを組み合わせたもの [8] などがある。モニタリングシステムで特に必要とされるのは、高齢者の日常生活行動の認識である。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。中でもトイレ行動は複数の動作 (移動・着脱・排泄・拭き取り) の連続で構成され個室で実行される。また、本研究ではトイレの個室にプライバシーの観点からカメラセンサを常設出来ない場合を想定しており、認識の際にカメラセンサを用いない他のアプローチでシステムの構築を検討していく。ウェアラブルセンサーではデバイスを身に着けないと認識をすることができず、付け忘れが懸念される。マットセンサー・ドアセン

<sup>1</sup> 電気通信大学大学院 情報理工学研究所 情報・ネットワーク工学専攻  
The University of Electro-Communications

サーでは、「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。近年では、WiFi や RFID などの無線通信技術を用いた行動認識アプローチが盛んに行われており、電波伝搬経路の間にいる人体に影響された受信信号強度 (Received Signal Strength Indicator, RSSI) や位相などの情報を解析することにより人の姿勢などの詳細な動作の認識をすることが可能になっている。そのため WiFi や RFID を用いることでデバイスフリーでプライバシーに配慮した行動認識システムを構築することができる。RFID に使われるタグの一種であるパッシブ RFID タグは、バッテリー不要で動作し様々なオブジェクトに貼り付けることができる。タグ一枚あたりにおけるコストも安価であり大量に用意することも可能である。さらに製品化された RFID リーダーでは周囲のタグを高速に読み取りそれぞれの RSSI と位相の情報を取得できる。これらの理由から RFID を用いることにする。本研究の目的として、RFID を用いた実用的なトイレ行動検知システムの実装・評価を行う。

## 2. 無線通信技術を用いた行動認識システムの課題

RFID を用いた既存研究の行動認識システムについて、RFID タグを人や物に装着する場合と壁に設置する 2 つの種類に関しての課題を述べる。

### 2.1 人や物

RFID タグを人に貼り付けて HAR 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、増田ら [9] が人体に UHF 帯のパッシブ RFID タグを複数枚付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ーと同様に付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「なにもないところで転ぶ」などの動作を認識することはできない。

### 2.2 壁

壁に RFID タグを貼り付けることでアンテナとタグ間にある人間の行動認識を行うアプローチがある [11], [12]。壁は動かない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 HAR 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言える。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。しかし「誰が」その行動をしたかという直接的な情報は取得できないため課題が残る。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。そのことからクラス分類タスクに置いて RFID タグの枚数はそこまで必要ではないと考えられる。不必要にタグの数が多いと RFID リーダーの読み取り速度の低下やデータセットの増加を招く。

これらは、デバイスフリーでアクティビティを検出することができるというメリットがある。しかし、問題点として機械学習手法で認識モデルを構築し特徴量の定義・分析・抽出を行っているため特徴量エンジニアリングのための無線通信技術の深い知識が必要になり構築コストが高い。

本研究はトイレ行動検知システムの構築にあたり、細かいアクティビティを認識可能であることを目的としている。そのため壁に RFID タグを貼るアプローチを採用する。

### 2.3 関連研究

様々なセンサー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) センサーとドアセンサーを利用して「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ーなどを持たせ、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た [14]。

## 3. 画像認識を用いた行動認識手法の提案

### 3.1 RFID によるデバイスフリーな認識における課題のまとめ

2 章から、RFID によるデバイスフリーな認識における既存研究の課題を整理すると、

- 信号からの特徴量解析・抽出を行っており、無線通信技術に熟知した者でないと作成できない
- 一枚のタグでは情報量が少なく細かい行動を認識できない
- 複数の RFID タグから得られた情報をアクティビティのクラス分類にのみ用いている

となる。また、本研究では細かいアクティビティの認識を行うために複数の RFID タグを 2 次元状に壁に設置する。

既存研究では、大量の RFID タグを用いて行っているのはアクティビティの多クラス分類である。

本研究では、大量の RFID タグからの豊富な特徴を考慮して多クラス分類に用いる前に、深層学習によるカメラ画像再現タスクを間に挟んだ新たな行動認識手法を提案する。それによって特徴量解析・抽出が不要となり、認識精度向上や骨格検出 [15] などの別のタスクに繋がられるメリットが得られる。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ことである。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繋げることも可能である。これによって、RFID タグからデータを取得した後は深層学習を用いて画像を再現するため特徴量解析・抽出を行う必要はなく、クラス分類以外のタスクに繋げることも可能になる。

本研究の提案は複数の RFID タグから得られた情報から人の姿勢を再現する処理が肝心となる。そのため、人の姿勢を捉える事ができるような RFID タグの配置方法を提案する。

### 3.2 タグアレイ




図 1 タグアレイの構成




図 2 シルエット検出のイメージ

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挙げられる。人体の頭部に遮られている場合に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。アンテナから発せら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

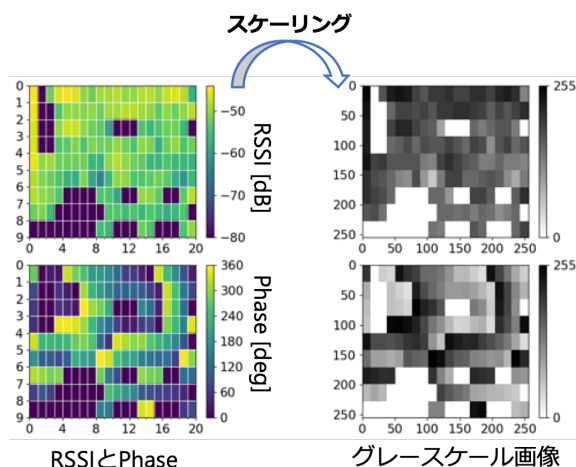


図 3 グレースケール画像化

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。左側のプロットの一つのマスはタグアレイに構成されている一枚のタグの 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 の値を取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 の範囲を取るようスケールリングを行う。Phase は、0-360 [deg] の値を取る。0-255 の範囲になるようスケールリングを行う。また、画像化の際には 256 x 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

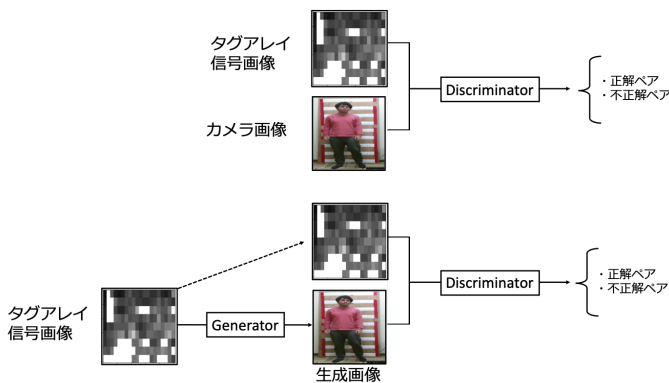


図 4 条件付き GAN の学習イメージ [16]

データセット構築の際には、RFID リーダーから各タグの 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 項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処理を実行する。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) の一つであり、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 [16]。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。

### 3.5 再現画像からの行動検知

最終的に CNN による画像分類を行うこと行動を検知する。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 つのプロセスに分割することができる。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

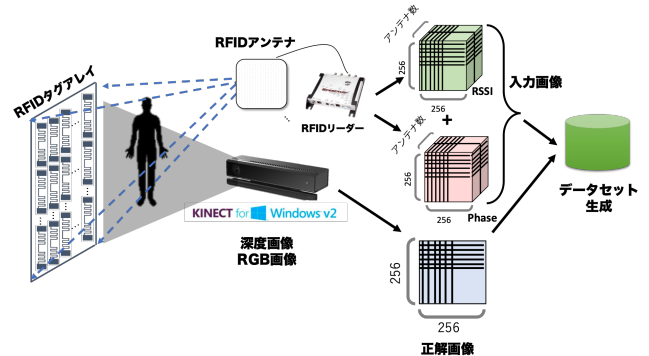


図 5 データセット生成

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収めるようにして間にいる人物の姿勢を捉え保存する。また、使用するアンテナの数によって入力次元は増減し、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 × タグアレイ横サイズ × 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。

### 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、これらを一枚の画像のように  $256 \times 256 \times 4$  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 を用いた。さらに、最適化関数には Adam 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。既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 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、epoch は 200 で Optimizer には SGD を使用した。

#### 4.5 画像生成・画像分類による行動検知




図 6 行動検知の流れ

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。最終的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予測というシナリオに対して適用しラベル付けから行動予測まで行う。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。トイレにはプライバシーの観点からカメラを設置して HAR を行うことは現実的でなく、本提案の効果を発揮しやすいと考えたためこのシナリオを適用した。また、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、協力者 4 名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は図 7 のようになっている。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。協力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

グ同士の間隔は横 10cm、縦 8cm 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。




図 7 模擬トイレの外観

#### 5.3 認識行動の定義



図 8 認識行動の種類

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 名の協力者が模擬のトイレ動作を行ったときの RFID 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。尚、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 4628 個であり教師データが 3725 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全てのデータセットを用いて pix2pix を学習した。Epoch は 450 で Optimizer には Adam を使用し、学習係数の初期値は 0.0002 で  $\beta_1$  は 0.5,  $\beta_2$  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。その結果、ラベル付けされた教師データが 2414 個で検証データが 715 個になった。

### 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された画像には現れていないものの、カメラ画像と概ね同じような姿勢を出力することができている。そのため画像の再現性は高く、後の画像分類には支障はないと考える。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ット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事による姿勢の変化を画像生成モデルが捉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 Epoch は 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。今回は pix2pix の入力に用いたタグアレイからの信号画像・pix2pix が生成した画像・Kinect から得られた RGB 画像の 3 つの教師用のデータソースから画像分類モデルの学習を行う。

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かけ精度を比較する。つまり、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。

次に、3 つの混同行列を示す。混同行列に表示されているラベルは図 8 に表示されているものと同一である。



図 10 タグアレイ画像の混同行列 平均精度=90.34%




図 11 生成画像の混同行列 平均精度=92.18%

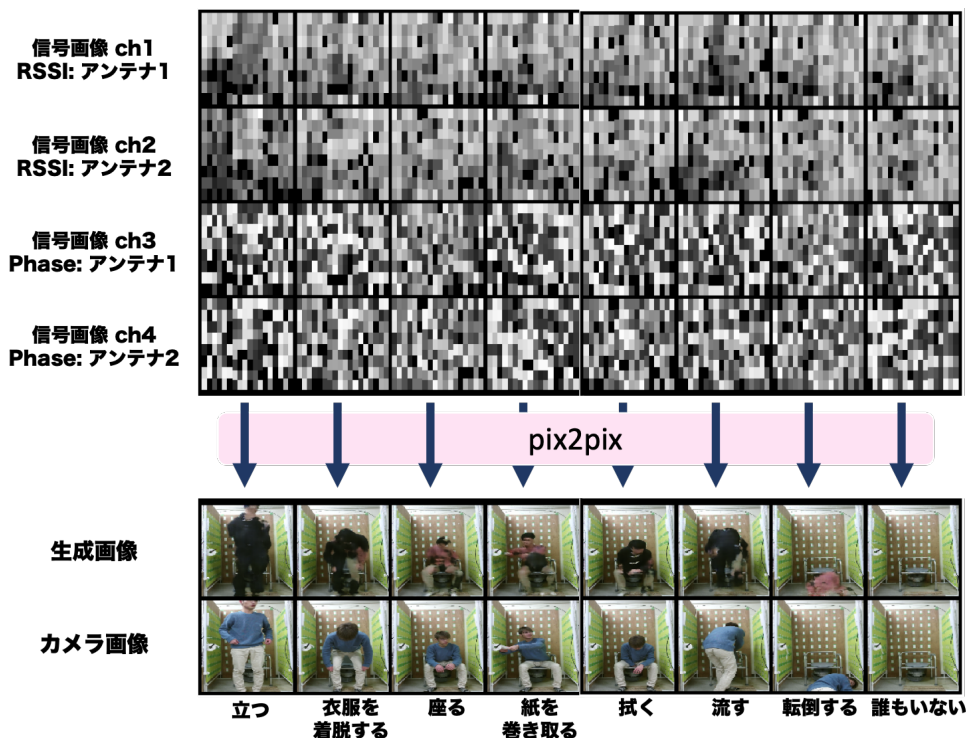


図 9 入力した信号画像と出力された生成画像および実際のカメラ画像

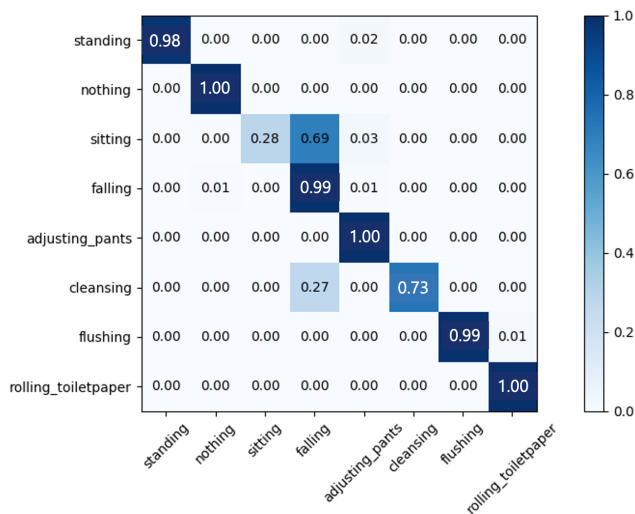


図 12 カメラ画像の混同行列 平均精度=91.87%

タグアレイから得られ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 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 toiletpaper)」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 項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。タグアレイ画像による画像分類と同じように、「座る (sitting)」の分類精度が悪い。

カメラから取得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 12 に示す。

表 1 分類の平均精度の比較

	平均精度 [%]
タグアレイ画像	90.34
生成画像	92.18
カメラ画像	91.87

タグアレイ画像・生成画像・カメラ画像それぞれでの平均分類精度を表 1 に示す。最も高い精度は pix2pix による生成画像を用いた場合だった。その理由として、pix2pix のモデルはラベル付けすることのできなかつたデータを含めて学習しているため教師用データが多くなっている。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掴んだ結果が精度の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精度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、服の色など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精度の差として現れたと考える。

## 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意識した実験構成となっており、協力者4名からのデータを取得している。画像の再現性評価では図9結果を出力するにあたり、テスト用データの人物は教師データには存在していないが、生成画像とカメラ画像の姿勢を比較すると粗はあるものの概ね姿勢は一致している。クラス分類実験では pix2pix が生成した画像を用いた場合の画像分類の精度が最も高くなっており、提案システムにおいてタグアレイ画像を pix2pix に入力しカメラ画像を再現するというタスクを挟むメリットを示すことができている。ただ、画像分類では学習の際に転移学習などを用いずに一から AlexNet で学習しているために、転移学習を用いた場合では平均精度がまた異なった結果になってくると考えられる。

## 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た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名の協力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捉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精度が92.8%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。

## 参考文献

- [1] 総務省統計局. 「高齢者の人口」, 2019. (<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との需給推計」, 2015. (<https://www.mhlw.go.jp/stf/houdou/0000088998.html>).
- [3] T. L.M. Van Kasteren, G. Englebienne, and B. J.A. Kröse. An activity monitoring system for elderly care using generative and discriminative models. *Personal and Ubiquitous Computing*, 14(6):489–498, 2010.
- [4] Andrea Mannini, Stephen S Intille, Mary Rosenberger, Angelo M Sabatini, and William Haskell. Activity recog-

- niton using a single accelerometer placed at the wrist or ankle. *Medicine and science in sports and exercise*, 45(11):2193, 2013.
- [5] Chenyang Zhang and Yingli Tian. RGB-D Camera-based Daily Living Activity Recognition. *Journal of Computer Vision and Image Processing*, 2:12, 2012.
- [6] Motoki Miura, Sadanori Ito, Ryoza Takatsuka, Taro Sugihara, and Susumu Kunifuji. An empirical study of an rfid mat sensor system in a group home. *Journal of Networks*, 2009.
- [7] Yukitoshi Kashimoto, Kyoji Hata, Hirohiko Suwa, Manato Fujimoto, Yutaka Arakawa, Takeya Shigezumi, Kunihiko Komiya, Kenta Konishi, and Keiichi Yasumoto. Low-cost and device-free activity recognition system with energy harvesting pir and door sensors. In *Adjunct Proceedings of the 13th International Conference on Mobile and Ubiquitous Systems: Computing Networking and Services*, pages 6–11, 2016.
- [8] Maja Stikic, Tâm Huynh, Kristof Van Laerhoven, and Bernt Schiele. Adl recognition based on the combination of rfid and accelerometer sensing. In *2008 Second International Conference on Pervasive Computing Technologies for Healthcare*, pages 258–263. IEEE, 2008.
- [9] 増田周弥, 沼尾雅之. Rfid を用いたリアルタイム状態検知システムの提案. 第8回データ工学と情報マネジメントに関するフォーラム (DEIM フォーラム 2016) G1-2, 3 2016.
- [10] Michael Buettner, Richa Prasad, Matthai Philipose, and David Wetherall. Recognizing daily activities with RFID-based sensors. *ACM International Conference Proceeding Series*, pages 51–60, 2009.
- [11] Lina Yao, Quan Z. Sheng, Wenjie Ruan, Tao Gu, Xue Li, Nick Falkner, and Zhi Yang. RF-Care: Device-Free Posture Recognition for Elderly People Using A Passive RFID Tag Array. In *Proceedings of the 12th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services*, pages 120–129. ACM, 2015.
- [12] George A. Oguntala, Raed A. Abd-Alhameed, Nazar T. Ali, Yim Fun Hu, James M. Noras, Nnabuike N. Eya, Issa Elfergani, and Jonathan Rodriguez. SmartWall: Novel RFID-Enabled Ambient Human Activity Recognition Using Machine Learning for Unobtrusive Health Monitoring. *IEEE Access*, 7:68022–68033, 2019.
- [13] Anthony Fleury, Michel Vacher, and Norbert Noury. Svm-based multimodal classification of activities of daily living in health smart homes: sensors, algorithms, and first experimental results. *IEEE transactions on information technology in biomedicine*, 14(2):274–283, 2009.
- [14] 創造 井上, 幸平 木村, 百里 内野, and 誠 大屋. 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, 九州工業大学, 株式会社 IDC フロンティア, may 2017.
- [15] Zhe Cao, Tomas Simon, Shih En Wei, and Yaser Sheikh. Realtime multi-person 2D pose estimation using part affinity fields. In *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, volume 2017-January, pages 1302–1310. Institute of Electrical and Electronics Engineers Inc., nov 2017.
- [16] Phillip Isola, Jun Yan Zhu, Tinghui Zhou, and Alexei A. Efros. Image-to-image translation with conditional adversarial networks. In *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, volume 2017-January, pages 5967–5976. Institute of Electrical and Electronics Engineers Inc., nov 2017.