

短時間パターン認識結果の投票的統合によるドア利用者識別

豊浦正広^{†1}
山梨大学

奥田雅也^{†1}
山梨大学

1. はじめに

カメラ画像からの人物識別は、ほぼ 100% の精度を実現する手法が多く登場している [1, 2, 3, 4]. 一方で、プライバシー保護や機密情報保護の観点から、家庭内や医療・介護施設内、企業内の IoT システムではカメラ画像の利用が避けられることも多い. 本研究では、ドアの利用者識別に焦点を当てて、カメラ画像を用いた人物識別を目指す.

カメラ画像を用いないことで容姿や表情などの不必要な情報を獲得せずに済み、心理的障壁を下げるができる. 初めから情報を獲得しないことによって、もしデータが漏洩したときにも被害を少なくすることができる. カメラを通して顔画像などの取得を制限する動きは世界中で広まりつつある. たとえば、EU は法執行当局による顔認証を含む生体認証の使用を禁止する規制案を発表しており [5], この規制は EU に居住する人には適用されるため、EU 域外においても規制が適用される.

SNS を通しての企業の情報流出も問題になっており、SNS にアップロードされた画像に移りこんだ個人情報の取り扱いについて、社会的な関心も高い [6, 7]. カメラは人間にとっても直感的に状況を認識しやすい一方で、認識のしやすさ故に、情報が流出したときには問題となることが多い. 本研究では、カメラなしで利用者の特定ができるようにする立場に立ち、その中でも屋内での人の行動追跡に有用であるドアの利用者を認識する手法を提案する.

本研究では 9 軸センサによる利用者の認証を目指す. 9 軸センサは軽量で低電力であることから、利用者に意識されにくく、電力確保もそれほど問題にならない. この点においても、9 軸センサは IoT デバイスとしてカメラよりも優れているといえる. 個人の認証には、ID カードや生体認証、PIN などを求める方法も考えられるが、これらはいずれもドアを開けるための手間を増やすことになり、紛失や盗難の問題も起る. 本研究で行うドアの利用者認証は、これらの認証に比べるとセキュリティ的には強固とはいえないものの、家庭内や企業内で利用者が限られた空間で用いて人の流れを追跡するために向いている. 認証の手間を増

やさないで、人の流れを妨げることもない.

ドアに取り付けた加速度からの利用者の識別を機械学習を用いて行う研究には先例 [8, 9, 10, 11] があるものの、精度は 90% 程度までにとどまっていた. 精度が高くならなかったひとつの原因は、SVM や古典的な DNN が採用されていたためである. 我々は Transformer[12] を含む新しいネットワーク構造を導入することで精度を高めた. もうひとつの原因は、学習のためのサンプル数が十分に集められなかったためである. 深層学習のためにはアノテーションの付けられた大量のデータが必要となるのが一般的である. 従来手法では、ドア 1 回の開閉で 1 つのサンプルとしていたために、現実的に十分なデータが得られなかった. この結果、十分にネットワークの訓練ができなかったものと考えられる.

我々はこの問題を解決するために、ドアの開閉による時系列 9 軸データを微小な運動の連続として捉えて、ネットワークの訓練に十分なサンプル数を確保する手法を提案する. 1 回のドアの開閉の中で投票を行うことで、最終的な利用者の識別を行う.

本論文の貢献は以下の通りであり、概要を図 1 に示す.

1. ドアの 1 回の開閉で 1 つのサンプルしか得られなかった従来の訓練方法に対して、ドアの開閉を微小な運動の連続と捉えることで、DNN の訓練に十分なデータを確保できるようにした. (4.1)
2. 複数のドアに取り付けて、複数の利用者を認識するための、マルチタスクネットワークをデザインした. ネットワークには Transformer を含み、時系列信号に対する効率的な訓練を実現した. (4.2)

本論文の構成は以下の通りである. 2. では、ドアのユーザを識別する手法に関する関連研究を紹介する. 3. では、実験を行った環境や条件を紹介し、データセットをいかに作成したかについて説明する. 4. では、Transformer を含むマルチタスク学習によるドアの利用者の手法を紹介する. 5. では実験結果を示し、6. で結論を述べ、今後の研究の方向性を述べて論文を締めくくる.

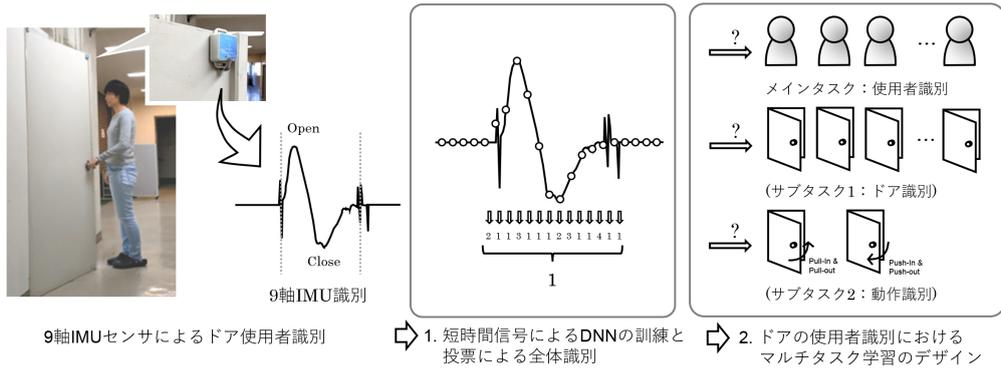


図1 提案手法概要. ドアに取り付けたセンサから得られる9軸信号を短時間の時系列信号に分解して認識する. 人・ドア・動作のそれぞれの認識を行う.

2. 関連研究

ドアの利用者識別のためには, カメラ [13], ID カード, ビーコン認証, 生体認証, PIN, スマートフォン認証 [14] などを利用する方法がある. カメラは利用者に特別なツールの持ち運びを要求しない利点があるが, 映像が流出した場合に, 格好や持ち物, 表情などといった不必要な情報が含まれ, 会社内や家庭内では使いにくいことがある. カメラ以外のツールでは, 一般的にドアを開ける以外の動作を必要とするために, さりげなく行動を管理したい IoT アプリケーションには向かない. スマートフォンによる認証 [14] では, ドアに取り付けたビーコンによって, ドアに近づくだけで認証する試みを行っているが, 6名の利用者で69%, 10名の利用者で62%の精度であり, 高い精度であるとはいえない. ただし, この研究では, ドアに近づくときだけにドアを開けるという機能が実現できており, むしろこちらに注力したように見える. 認証ツールを紛失したり忘れたりしたときに, ドアを開けられなくなるリスクは残る.

ドアの利用者識別のために, ドアに取り付けた加速度センサを用いる先行研究がある. Piltaverら [8] は, ドアに取り付けた加速度センサのデータから, 登録されているデータとの照合を行うことによって, 12名の被験者を89.9%のaccuracyで識別した. Dynamic Time Warping(DTW)によって時間方向の変化を吸収し, 得られる特徴量をk-NNによって照合することで, 識別精度を向上した. Fukaoら [9] は, ドアノブに取り付けたジャイロセンサから利用者の識別を行い, 4名の識別に入室時には0.73, 退室時には0.90のF-measureを得た. 彼らの手法では, ドアノブを回す動作だけで利用者を認識するので, 認識結果によってはドアを開けないシステムを開発することもできる. 同じ研究グループ内のIshidaら [10] は, 冷蔵庫のドアの開閉についても似た技術で7名をBayesian Networkによって91.9%の

accuracyで識別した. Vegasら [11] も, ドアハンドルの端に加速度センサとジャイロセンサを取り付けてユーザの識別を行った. DTWで加工した特徴量をSVMやANNを用いて学習し, 47名の利用者に対して0.912のAUC値を得ることができている.

いずれの研究においても, 機械学習でそれほど高い精度を得ることができていなかった. いずれも単一のドアに対する識別であり, ドアを変更したときの識別率については言及されていない. 深層学習に耐えるだけのドアの開閉データのサンプルを多数集めることが難しく, 比較的簡単な学習器によって識別を試みているところに問題が残ると考えられる. また, 網羅的に列挙したハンドクラフト特徴量では, 特徴量の次元を低く抑えることはできるものの, データの特徴を十分に表現できなかったのではないかと, 我々は推察する. 本研究では, 少数の試行からデータを大量に集めて, 深層学習の自動特徴抽出によって, 認識精度を向上させることを目指す.

加速度センサからの人間行動推定では, 運動の種類を識別するがあり, 本研究で利用するTransformerを含めて, 深層学習も積極的に取り入れられている [15, 16, 17, 18, 19]. ミーティング中の人間行動に特化して, その行動の検出を目指した研究もある [20]. FitbitやGARMIN, Apple watchといったような民生用のウェアラブルウォッチでも, 睡眠や歩行, 自転車等の生活行動の認識が提供されており, 生活の中に浸透しているIoTデバイスとなっている. これらの手法は加速度センサを人が装着することを想定しており, モノに取り付けて受動的に人間の行動を推定する本研究とは立ち位置が異なるものの, タグ付けや認識手法の一部は大いに参考になる. Hassanら [19] は, ウェアラブルセンサの信号から人間行動認識を目指し, 2.56秒分の信号波形から, 平均値や絶対値, 周波数成分の歪度・尖度, エントロ

ピーなどの 17 のハンドクラフト特徴量を設計した。識別器についても、1 層のニューラルネットワーク、SVM、3 層のニューラルネットワークについて試行を行っている。最終的には、この 17 の特徴量を 3 層のニューラルネットワークで学習することによって、立つ・座る・歩く・横たわるなどの 12 種類の行動を 89.61% で認識した。カテゴリによっては十分なサンプル数がないとも論文数に書かれている。サンプル数が大量に得られないときには、自動で抽出される特徴量を得ることも、より深いニューラルネットワークを用いることも難しくなる。5. に示す実験では、手動抽出の特徴量の精度の違いについても、検討する。

3. ドア信号の取得

ドアに簡易に取り付けた 9 軸センサによって、ドアの利用者の識別を目指す。

3.1. ドア動作による 9 軸信号の特性

ドアには図 2 に示すように、ドアフックに取り付ける形で 9 軸 IMU センサ WitMotion WT901SDCL を取り付けた。ドアの上部に取り付けることで、利用者は特に意識することなく、ドアの開閉をすることができる。同製品は SD カードを挿入すれば 9 軸データの収録を開始し、SD カードを取り出せばデータの収録を停止する。一度収録を開始すれば、数時間はバッテリーが持続するので、複数人の実験にも利用可能である。将来的にはソーラーバッテリーなどへの接続によって充電を不要にし、Bluetooth 接続などでセンサに触れることなくデータを取り出すことを目指す。同社製製品には Bluetooth 接続のものがあるが、獲得できる信号周波数が低いことなどから、今回の製品を採用した。

9 軸センサによって、200Hz までの加速度・角速度・地磁気 of データを取得することができる。Bluetooth で通信する装置では、バッテリーの減りが早くなり、データの欠損も起こりやすくなる。データ欠損を避けるためには、周波数は 200Hz 未満に落とすことも可能であるが、従来研究 [19] に従い、デバイスの上限速度である 200Hz とした。通信によるデータ損失を避けるために、装置に内蔵された SD カードに信号を保存し、あとからデータを手動で取り出すこととして、実験を進めた。図 2 はドアの外から入ってドアを閉め、中から再度ドアを開けて外に出てドアを閉めたときに、取得できる信号の例を示す。

ドアの利用者を認証して制限するような機能はないため、ドアを利用した後に利用者を識別するにとどまる。ドアノブの動きを抽出することによって、ドアの開閉前に利用者の認証をすることもできる [9] が、本論文では高度なセキュリティまでは要求しないような、建物内の人の動きの記録を想定して、ドアノブではなく、ドア上部の動きの推定を

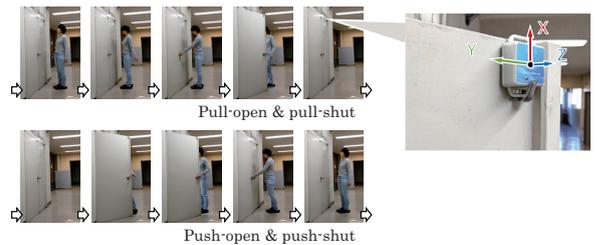


図 2 各軸の向き。X 軸はドアの上方向、Y 軸はドアの水平方向、Z はドアの手前方向とした。実験の様子。ドアの上部の最も移動量が大きくなる位置に 9 軸センサを取り付けてある。軽量であり、利用者はセンサを意識することなくドアを開閉することができる。

行った。

3.2. ドア信号に対するアノテーション付与

収録したドアセンサのデータを教師あり学習のための訓練データにするためには、どの時刻のデータが、どの利用者・どのドア・どの動作に対応するのかのラベルを付与する必要がある。どの利用者であるか、どのドアであるかは比較的明確にラベルを付けることができる。実験時には、ある実験参加者だけが、あるドアを開閉するためである。動作には、引いて開けて引いて閉める、押して開けて押して閉めるの 2 通りがあることになる。こちらもこの 2 つの動作が繰り返し出現するので、どちらから始めたかだけを記録しておけば、容易にラベルをつけることができる。

ドアが開き始めてから閉まり終わるまでを特定することは、意外に難しい。センサ信号のパワーを見ることで、ドアに人が触れているかを推定することはできるものの、ドアから手が離れてしばらくの間には、ドアが振動してパワーが十分に小さくならないためである。また、センサにはジッターノイズが載るために、実際にはドアが揺れていなくても、センサ信号のパワーは大きくなることがある。ドアから手が離れたものに対して、利用者が誰であるとか、動作がどうであるかというラベルを振ってしまうと、利用者に依らずに同じようなパターンを描くことになるために、ネットワークの訓練がうまく行かないことが予想される。ドアに手が触れている時間帯をできるだけ正確に判定したい。

センサ信号を 1 動作ごとに切り分けるためには、図 3 に示すように、センサ信号をまず平滑化して、ジッターノイズを除去する。平滑化のためには、従来手法 [19] でも用いられているバターワースフィルタを利用した。平滑化した上で、パワーに閾値を設けて、ある閾値を超えたときに動作が開始し、ある閾値を下回ったときに動作が終わったものとみなした。ドアの振動が十分に収まらないうちに、次の開

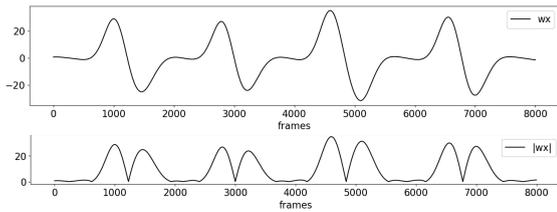


図3 x 軸回りの角速度の解析によるドア信号の切り分け

閉動作が始まってしまうときには、閾値処理によってうまく信号が切り分けられないことがあるので、ドアの開閉の回数が記録したものよりも少なくなるときには、時系列信号を目視で確認して、パワーの谷となるところで、動作が完了し、すぐに始まったものとみなして、時間帯の設定を修正することとした。

4. Transformer を含む DNN による信号解析

4.1. 短時間分割サンプルと投票

従来の IoT センサパターン認識では、1 パターンの開始から終了までの特徴を捉えることで認識を行ってきた。この方法の問題はいくつかある。まず、(1) 時間長の異なるパターンを扱う必要があることである。次に、(2) 開始と終了の時刻が正しく得られないと、パターンが異なって見えることである。さらには、(3) 1 回の動作で 1 サンプルしか得られないために、DNN の訓練に必要なサンプル数を準備するのに労力がかかることである。

(1) に対しては、パターンに対してフェーズを手動で定義して、それぞれのフェーズの継続時間や波形を解析する手法が提案されている [11]。パターンをモデル化して認識するので、モデル化からずれたパターンでは認識がうまくいかない。ハンドクラフト特徴量を設定せずに、データのみから特徴を抽出する深層学習の利益も得られにくい。

(2) に対しては、3.2 で述べる通り、単純なドアの開閉パターンであっても、開始と終了の時刻は判断がしにくい問題がある。データセットを作成するときには手動でタイミングは設定できるが、実行時には自動でタイミングが得られる必要があり、これに失敗すると、その後の認識はさらに難しくなる。

(3) に対しては、実験参加者により多くの試行を重ねてもらう必要がある。ドアの種類が増えれば、またそれだけ試行回数を増やす必要がある。ファインチューニングなどによって新しいドアに対するネットワークを獲得しようとするときには、新しい利用者により多くの試行を再度重ねてもらわなければならない。サービスの実現が難しくなる。

本研究では、時系列センサ情報を細かく分割して、それぞ

れの分割データに対して認識を行うようにすることで、(1) から (3) の問題を解決する。最終的には、開始から終了までの認識結果で投票を行うことによって、1 動作に対する認識結果を得るようにする。この方法だと、パターンの時間長に影響されにくく、開始・終了の時刻のずれに対する影響も少なく済む。細かく分割したデータの数は大量になるので、実験参加者には少数回の試行を行ってもらっただけで、訓練に耐えうるサイズのデータセットを準備することができるようになる。

実行時には、一度に複数回の開閉が連続することは考えにくいので、このような時間帯の分割の失敗が起こることは、あまり想定する必要はないものとする。もし分割に失敗しても、後に述べる短時間ごとの認識とその投票のアルゴリズムはそのまま使えるので、大きな問題にはならないものとする。それでも失敗するような一連のセンサデータに対しては、認識をあきらめて、次の動作の認識を試みるのがよいと考えることとした。

4.2. マルチタスク学習と Transformer による認識

観測される時系列信号には、利用者の特徴の他に、ドアの特徴や動作の特徴が反映される。たとえば、同じ利用者であっても、ドアが異なれば観測される信号が変わる。言い換えると、利用者を認識するためには、ドアの影響を考慮する必要がある。従来手法では、どんなドアであっても人が正しく認識できるように、様々なドアで実験を繰り返して、ドアの影響を排除することを目指してきた。この方法では、多くの試行を行う必要があり、実際に利用するドアが少数であっても、多数のドアでの実験が必要となる。

この問題を解決するために、マルチタスク学習を導入した [21]。メインタスクに利用者の認識を設定し、サブタスクにドアと動作の認識を設定した。マルチタスク学習では、サブタスクを考慮した上でメインタスクを行うことによって、メインタスクで考慮すべきことが深層ネットワーク上の重みとして実現される。動作は、ドアを押して開けて押しつけて閉める (push-in-push-out) と引いて開けて引いて閉める (pull-in-pull-out) の 2 種類とした。ドアに対してどちらの動作をするかによって、観測される時系列信号が異なることが予想されるためである。また、この動作が認識できれば、ドアのどちらから入ってどちらから出たかも把握でき、実用上も意味がある。

具体的なネットワークとして、図 4 に示すネットワークを構築した。入力される時系列信号から、人・モノ・動作の 3 つの認識結果が得られるように構成されている。ネットワーク内には、時系列信号をうまく扱える Transformer [12] を採用している。これによって、1 時刻だけの信号だけではなく、その時刻に至るまでの一連の時系列信号を考慮して、

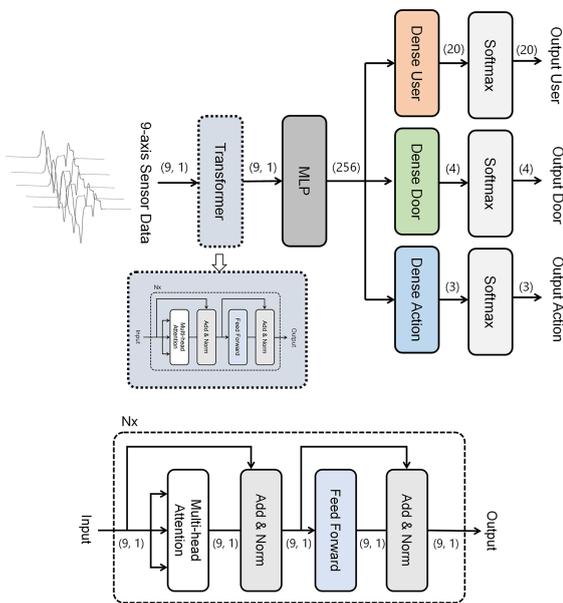


図4 マルタスク学習に用いたネットワーク. 人・ドア・動作のそれぞれの認識を行う.

最終的な認識結果を得ることができるようになる. 3. で述べたデータセットの信号が入力されると, 対応する正解タグが教師ラベルとなって, 深層学習ネットワークの訓練が行われる.

5. 実験

人・ドア・動作がそれぞれ認識できるかを確かめるために, 実験協力者を集めて実験を行った.

5.1. データセットの収集

実験では, 5つのドアの上部の端から 3cm の位置に 9 軸 IMU センサを取り付けて, 20 名の実験協力者 (11~42 歳, 男性 15 名, 女性 7 名, 3 名は利き手が左手で残り 17 名は右手) がドアを開閉するときのセンサ信号を収録した. 各被験者にはそれぞれのドアを 30 回ずつ開閉してもらった. ドアの開閉回数は, 横で見ている実験実施者がカウンタを使って数え, 規定回数になって時点で実験参加者に伝えるようにした. 毎回の開閉後にはドアノブから手を離して, 一呼吸おいてもらうように指示した.

ドアから手を離してしばらくすると, 9 軸 IMU センサで得られる信号のパワーが小さくなるのが期待できる. 少しの間はドアの振動が残っているために, センサ信号のパ

ワーは残っている. 信号のパワーに閾値を設けることで, 1 回ずつのドアの開閉の信号を切り分けた.

ドアが開閉する時系列信号に対して, 利用者・ドア・動作のタグが 1 つずつ与えられる. 実験では 1 つのドアに対する 30 回の開閉を 1~14 回目の 14 回を学習用, 15~20 回目の 6 回をテスト用, 21~30 回目の 10 回を検証用に分割した. 競争相手となるニューラルネットワーク以外の学習器に対しては, 1~20 回目の 20 回を学習用, 21~30 回目の 10 回を検証用とした.

5.2. 特徴量および学習器の違いによる精度比較

提案する深層ネットワークでどれほど正しく利用者を識別できるかを検証した. 比較のために, 先行研究で実績があった 3 層のニューラルネットワーク (FCN), ランダムフォレスト, 最近傍法によっても, 利用者の識別を試みた. 実装はそれぞれ Python と Tensorflow を使い, Google Colaboratory で実行した. 従来手法と比べて, 論文に記載された値に対して上下するものがあるが, 処理対象のデータセットが異なるためである. 特に, 従来手法では異なるドアによって実験を行っているものではなく, 異なるドアの動きから同じ利用者であることを識別するのは, より難しいタスクとなっている. また, 短時間識別結果を多数決して得たことも結果に影響している.

まずは, 入力に Hassan ら [19] が提案した 17 次元のハンドクラフト特徴量を採用したときの結果を示す. 入力信号は短時間信号に分割したうえで, 17 次元のベクトルに変換されて, 学習器に入力される. 最終的には, 一動作に対する複数の識別結果を多数決して結果を得る. 従来手法 [19] で良好な結果を得ていた FCN に対しても, 0.040 だけ優れた結果が得られている. さらに, Transformer を導入することによって, 時系列の変化をよく捉えることができ, 結果がさらによくなったと考えられる.

表1 学習器の違いによる精度比較. Hassan ら [19] が導入したハンドクラフト特徴量を学習器の入力とした.

学習器	正解率	適合率	再現率	F 値
FCN	0.898	0.899	0.898	0.898
Random Forest	0.897	0.899	0.898	0.897
Nearest Neighbor	0.718	0.734	0.716	0.717
Proposed	0.939	0.939	0.939	0.938

次に, 入力に 9 軸信号を直接採用するときの結果を示す. 提案手法のみで, ハンドクラフト特徴量を入力とするときよりも, よりよい結果が得られている. その他の手法では, 時系列信号の特徴を扱う部分がなくなるので, 結果は悪くなっている. 提案手法では, 深層学習で得られる時系列特

徴がネットワークで表現されており、よい結果を得ることができている。ドア信号を表現するためには、17次元の手作り特徴量よりも直接に9軸信号を直接入力したときの方が、優れた学習器を作ることができた。

表2 学習器の違いによる精度比較。時系列の原信号を入力とした。

学習器	正解率	適合率	再現率	F 値
FCN	0.800	0.800	0.800	0.799
Random Forest	0.875	0.874	0.875	0.874
Nearest Neighbor	0.649	0.654	0.649	0.648
Proposed	0.973	0.973	0.973	0.973

従来研究のうちでドアに対して利用者の識別を行ったものを選び、得られる正解率 (accuracy) を表3にまとめた。複数のドアに対して利用者識別を試みたものはなかった。Vegasらの手法[11]の検証のためには、この論文の実験よりも多くの利用者を識別しており、単純に優劣を比較はできない。その他の手法に対しては、多くの利用者とも多くのドアに対して、より高い精度を示しており、提案手法の方がよい結果を出している。

6. Discussions and future work

本研究では、カメラ画像に依らずにドア利用者の識別する手法を提案した。9軸センサの信号からの識別によって、カメラ画像を用いるときには問題となるプライバシー保護や機密情報保護に関する問題を解決した。

ドアの開閉を微小な運動の運動の連続として捉えることで、DNNの学習に十分なデータを確保できるようにし、Transformerを含むマルチタスク学習ネットワークを採用することによって、実験参加者20人を0.973の正解率で識

表3 各手法による認識結果

手法	対象	条件	正解率
Piltaver et al. [8]	Door	12 users, 1 door	0.899
Vegas et al. [11]	Handle	47 users, 1 door	0.912
Fukao et al. [9]	Knob	4 user, 1 door	0.900
Ishida et al. [10]	Fridge	7 users, 1 door	0.919
Proposed	Door	27 users, 5 doors	0.973

表4 ドアと動作の認識結果

	クラス数	正解率
ドア	5	0.965
動作	2 (pull-open and push-open)	0.687

別することができた。

ドアや動作の種類の推定精度についても議論することができる。提案手法では、5つのドアの認識精度と、pull-openとpush-openの認識精度は、表4に示す通りであった。ドアの種類はよく推定できるが、どの方向から開けたかはそれほどわからないことが、表から読み取れる。種類の数から考えると、それぞれ0.2と0.5がベースラインとなる。センサを取り付けるときにどのドアであるかはわかるので、推定することに意味があまりない状況も多い。利用者が1つのセンサを別のドアに付け替えたり、ドア以外のモノに取り付けるときには有用になる場面があるかもしれない。

実験では、通信によるデータ損失を避けるために、SDカードに保存した9軸信号をあとから取り出す方法を採用した。通信によって、バッテリーの消費が早くなるという問題も生じる。実験では従来手法に倣って200Hzでの信号解析を行ったが、これほど高い周波数でなくとも解析ができる可能性はあり、より小さな周波数を設定することで、データの損失やバッテリーの消費を軽減できる。今後、人を識別するのに必要な下限の周波数について検証を進めたい。また、Bluetoothなどによる通信によって、実時間で利用者を識別するドアの開発を行いたい。

謝辞

本研究はJST さきがけ JPMJPR213 の支援を受けた。

参考文献

- [1] F. Schroff, D. Kalenichenko, J. Philbin, "Facenet: A unified embedding for face recognition and clustering," Proc. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 815-823, 2015.
- [2] Fu, M. Fu, S. Sun, H. Gao, D. Wang, X. Tong, Q. Liu, Q. Liang, "Improving Person Re-identification using A Self-focusing Network in Internet of Things," IEEE Internet of Things Journal, 2021.
- [3] Z. Cheng, X. Zhu, S. Gong, "Surveillance Face Recognition Challenge," 2018.
- [4] S. Afra and R. Alhajj, "Early warning system: From face recognition by surveillance cameras to social media analysis to detecting suspicious people," Physica A: Statistical Mechanics and its Applications, vol. 540, pp. 123151, 2020.
- [5] EU FRA, "Facial Recognition Technology: Fundamental Rights Considerations in the Context of Law Enforcement," ed: Publications Office of the European Union Luxembourg, 2019.
- [6] K. Sarikakis and L. Winter, "Social Media Users' Legal Consciousness About Privacy," Social Media + Society,

- vol. 3, no. 1, , pp. 1–14, 2017.
- [7] I. Mutambik, J. Lee, A. Almuqrin, W. Halboob, T. Omar, A. Floos, “User concerns regarding information sharing on social networking sites: The user’s perspective in the context of national culture,” *PLOS ONE*, vol. 17, no. 1, pp. e0263157, 2022.
- [8] R. Piltaver, H. Gjoreski, and M. Gams, “Identifying a person with door-mounted accelerometer,” *Journal of Ambient Intelligence and Smart Environments*, vol. 10, pp. 361-375, 2018.
- [9] A. Fukao, K. Futami, and K. Murao, “An Individual Recognition Method based on Door Opening and Closing Motion using a Gyroscope,” *Applied human informatics (AHI)*, vol. 3, no. 1, pp. 1-11, 2021.
- [10] A. Ishida, K. Murao, T. Terada, and M. Tsukamoto, “A user identification method based on features of opening/closing a refrigerator door,” in *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, 2017, pp. 533-538: IEEE.
- [11] J. Vegas, C. Llamas, M. A. González, and C. Hernández, “Identifying users from the interaction with a door handle,” *Pervasive and Mobile Computing*, vol. 70, p. 101293, 2020.
- [12] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, L. Kaiser, I. Polosukhin, ”Attention is All You Need,” *Advances in neural information processing systems*, vol. 30, 2017.
- [13] M. Ye, J. Shen, G. Lin, T. Xiang, L. Shao, and S. C. Hoi, “Deep learning for person re-identification: A survey and outlook,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 44, no. 6, pp. 2872-2893, 2021.
- [14] W. Shao, T. Nguyen, K. Qin, M. Youssef, and F. D. Salim, “Bledoorguard: a device-free person identification framework using bluetooth signals for door access,” *IEEE Internet of Things Journal*, vol. 5, no. 6, pp. 5227-5239, 2018.
- [15] A. Bayat, M. Pomplun, and D. A. Tran, “A study on human activity recognition using accelerometer data from smartphones,” *Procedia Computer Science*, vol. 34, pp. 450-457, 2014.
- [16] A. Ignatov, “Real-time human activity recognition from accelerometer data using Convolutional Neural Networks,” *Applied Soft Computing*, vol. 62, pp. 915-922, 2018.
- [17] S.-M. Lee, S. M. Yoon, and H. Cho, “Human activity recognition from accelerometer data using Convolutional Neural Network,” *Proc. IEEE International Conference on Big Data and Smart Computing (bigcomp)*, pp. 131-134, 2017.
- [18] Y. Shavit and I. Klein, “Boosting Inertial-Based Human Activity Recognition With Transformers,” *IEEE Access*, vol. 9, pp. 53540-53547, 2021.
- [19] M. M. Hassan, M. Z. Uddin, A. Mohamed, and A. Almo-
- gren, “A robust human activity recognition system using smartphone sensors and deep learning,” *Future Generation Computer Systems*, vol. 81, pp. 307-313, 2018.
- [20] A. Ohnishi, K. Murao, T. Terada, and M. Tsukamoto, “A method for structuring meeting logs using wearable sensors,” *Internet of Things*, vol. 5, pp. 140-152, 2019.
- [21] Y. Zhang and Q. Yang, “A Survey on Multi-Task Learning,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 34, no. 12, pp. 5586-5609, 2022.