

携帯型加速度・照度センサによる部屋からの退出推定手法

磯田達也¹ 井上 創造¹ 忽那秀治² 河野正人²

概要：現在、オフィス内などでの入館証・社員証などは、そのほとんどがICカードでの運用が主流となっている。ICカードによる入退出認証の場合、入口の壁などに専用のカードリーダー等を設置して行うことが一般的である。しかし現実にはオフィスでは入室時のみしか認証を行わないケースが多く、その場合、その部屋に入室したことは判断できても、その後いつ部屋から退出したかを知ることはできない。しかし、退出時にもカードリーダーを利用するとなると人間の手間も増えることになり面倒である。さらに、カードリーダーや空調、照明などのスイッチ等を壁に多く取り付けるような行為は、コストも多くなり、景観を損なうことにもつながる。そこで我々は、携帯情報端末に搭載された加速度センサおよび照度センサから得たデータを使用し、人の退室を判断する手法を提案する。今回我々は、部屋からの退出時に起こる周囲の環境変化および、退室者の行動情報から、退出を判定できるかどうかの実験を行った。人間は基本的に、止まっている状態では退室行動を行えないと考えられる。提案手法は、加速度データから取り出した特徴量から歩行のデータのみを判別して抽出し、そのデータの中で照度の特徴量を見てさらに退室のデータを判別するというものである。提案手法を用いて機械学習を行った結果、被験者でデータを区別した場合の判別結果が87.60%という結果となり、もっとも高い結果であった。

Recognizing Room Exits from Mobile Accelerometers and Illuminometers

TATSUYA ISODA¹ SOZO INOUE¹ SHUJI KUTSUNA² MASATO KAWANO²

1. はじめに

近年、会社のオフィス等ではICカードとカードリーダーを用いた入室システムが普及している。しかし、入室したことは認識できても、退室時にはカード認証を行わないことが多い。つまりいつ入室したかは判定することができるが、退室は認識していることが少ない。部屋からの退出を正確に判定することができれば、人間のいない部屋の照明や空調等をこまめに管理することで消費電力の削減につながる。本研究では、現在広く普及してきた携帯情報端末に注目した。携帯情報端末には行動推定を行う上で多く利用されている3軸加速度センサのほかにも角速度センサや照度センサ、音センサなどの様々なMEMSセンサが搭載されており、多くのセンサデータの収集が可能である。この携帯情報端末によって部屋からの退室判定ができれば、建物自体に様々なセンサを取り付ける必要もなく、コスト削

減につながり部屋の景観もよくなる。

本研究では、携帯情報端末に搭載された照度センサデータおよび加速度センサを用い、部屋からの退出を判定するための手法を提案する。人間は基本的に、止まっている状態では退室行動を行えないと考えられる。提案手法は、加速度データから取り出した特徴量から歩行のデータのみを判別して抽出し、そのデータの中で照度の特徴量を見てさらに退室のデータを判別するというものである。部屋からの退出時には、周囲の環境に何らかの変化があるのではないかと考えられるため、今回の実験では周辺環境の照度変化および被験者の加速度の変化を利用して、部屋からの退出を判定できるかどうかの実験を行った。実験によって得られたデータから特徴量を算出し機械学習を行い退室の判別精度を検証した。判別の結果、被験者でデータを区別した場合の判別結果が87.60%という結果となり、もっとも高い結果であった

以下第2章で関連研究について述べ、第3章に提案手法、第4章に評価方法と続く。第5章で評価結果について

¹ 九州工業大学

² 株式会社 NTT ファシリティーズ

の考察を述べ、第 6 章で本稿をまとめる。

2. 関連研究

近年、加速度センサや角速度センサ、磁気センサ、気圧計といった MEMS センサを有する装着型センサを用いて、人間行動を把握するための研究が多く行われている [1-3]。これまでこのような人間行動の計測は難しく、音声認識や画像認識に比べて実用化されるものが少なかったが、近年、iPhone や Android 端末といった MEMS センサを搭載した携帯情報端末の普及に伴い、人間の行動の計測がより簡単に可能となった [4]。このような装着型センサは、比較的安価で、小型かつ軽量なものが多く、持ち運びに便利であり被験者や利用者への負担も最小限に抑えられるため、様々な場面での運用が期待されている。これらの装着型センサによって得られたセンサデータを用いて人間行動を推定することで、様々な分野への応用が期待できる。例えば医療分野においては、人々の生活習慣を客観的に計測することで、生活習慣病の予防が期待できる [5]。また、医療業務 [6-8] は業務の転換や割り込みが多く発生することから、業務管理と医療事故を未然に防ぐために、行動識別処理を結合した分析ツールの研究も行われている。農業分野においては、農業従事者の行動記録を得ることができれば、作業の効率化を図ることが期待できる。スポーツやダンス、伝統芸能のような特有の動きが重視される分野では、これらの動きの行動推定から手本となる行動にどれだけ近いかを評価することができれば、客観的に習熟度を確かめる [9,10]。

現在、オフィス内などでの入館証・社員証などは、そのほとんどが IC カードでの運用が主流となっている。IC カードによる入退出認証の場合、入口の壁などに専用のカードリーダー等を設置して行うことが一般的である。

しかし現実にはオフィスでは入室時のみしか認証を行わないケースが多く、その部屋に入室したことは判断できても、その後いつ部屋から退出したかを知ることはできない。そのため、全員が退出して誰もいなくなった部屋の空調や照明が消えていないような場合も多く、電力等のコスト削減においての大きな弊害のひとつとなっている。例えば昼休みの時間帯も照明がついたままであったり、残業時間帯も必要以上に照明をつけているようなことが原因として挙げられる。

そのため、入室だけでなく退出に関する情報もリアルタイムで得ることができれば、だれもいない部屋の空調や照明等をこまめに自動で消すことができ、コスト削減、省エネにつながるはずである [11]。しかし、退出時にもカードリーダーを利用すると人間の手間も増えることになり面倒である。さらに、カードリーダーや空調、照明などのスイッチ等を壁に多く取り付けるような行為は、コストも多くかかり、景観を損なうことにもつながる。また、さ

まざまなセンサを設置すると点検や整備などの手間もおおくかかることになる。

そこで建物自体になるべくセンサ等の機器を設置せずに、退出を判断することにより電力等のコスト削減を行う方法として、我々は携帯情報端末を用いることを提案した。現在の携帯情報端末は小型化されており、様々な MEMS センサが搭載されている。これらのセンサから得られたセンサデータを利用することで、人間の退出判断が可能だと考えられる。

3. 提案手法

本章では、携帯情報端末に内蔵されたセンサを用いて人間が部屋から退出する行動を判定するための検証実験と解析の手法について述べる。退出判断のための加速度および照度センサデータによる学習と推定手法について提案する。

3.1 特徴量計算

本節では、実験によって収集した加速度および照度センサデータの解析手法について述べる。

実験によって得られると想定されるセンサデータは、被験者が照度の違う様々な環境下で部屋からの退室行動を行う間に携帯情報端末で得られた加速度センサおよび照度センサデータである。収集した生データには 3 軸方向のそれぞれの加速度や照度のセンサデータが含まれている。生データをそのまま解析に利用するのは難しいため、データの特徴量を計算する必要がある。特徴量計算を行うために、まずデータをある一定時間ごとに分割して領域ごとに焦点を絞る。この領域のことを、時間窓 (タイムウィンドウ) と呼ぶ。この時間窓ごとの特徴量を計算し、設定した時間ごとに時間窓をずらしていきながら、時間窓内のデータに対して様々な処理を行うことによって特徴量を計算してゆく。ここで時間窓をずらしていくために設定した時間のことをずらし幅と呼ぶ。

本研究では 10 秒ごとに時間窓を設定し、時間窓のずらし幅は 1 秒間隔とした。照度センサのデータは平均値、差分の和、最大値、最小値、最大値と最小値の差を計算し、特徴量とした。ここで述べた差分の和とは、時間窓内の最後の値から最初の値を引いた値である。一方加速度センサのデータにおいては、3 軸の 2 乗和平方を取り、分散を計算した。こうして得られた各センサデータの特徴量データを用いて次節の機械学習を行ってゆく。

3.2 機械学習

機械学習で判別を行うためには、お手本となる教師データが必要となる。得られた特徴量データから学習用特徴量を抽出し、このデータを用いて機械学習を行う。人間は退室行動を行うための条件として、必ず歩いたり走ったりといった何らかの行動を行っていかなくてはならないはずであ

る。人間の行動認識には加速度データを用いることが有効である。

そこで我々は今回、次のような学習手法を提案する。学習用特徴量の中の加速度および照度センサデータの特徴量に注目して、以下で述べる学習手法を用いて機械学習を行う。加速度特徴量によって行動を行っているかどうか、照度特徴量によって退室中かどうかをそれぞれ判別する。

4. 評価

本章では、携帯情報端末を使った退室判定実験を行うにあたり、提案手法が有用であるか評価する。

携帯情報端末に搭載された MEMS センサを用いた、部屋からの退室判定の精度を検証するために評価実験を行った。携帯情報端末に搭載された加速度および照度センサを用いて部屋からの退室を行う過程においてのデータを収集した。収集したセンサデータの特徴量を計算して結合して、そこから指定した時間の学習用特徴量をピックアップし、機械学習を行って退室の判定精度を検証した。解析のためのプログラムは統計解析ソフト R で作成し、機械学習の分類機には SVM (Support Vector Machine) [12] を用いた。

4.1 データセット

評価実験を行うにあたり、携帯情報端末を用いてデータ収集を行った。4つの実験環境において、2通りの実験パターンを5人の被験者に3回ずつ行い、120件のデータを収集した。さらに環境変化におけるセンサデータの変化を知るために、これらの実験を昼と夜の2回に分けて行うため、最終的に240件のデータを収集できた。

4.1.1 実験環境

退室時の状況は、周囲の照度や人間の行動パターンなどによってそれぞれ違うため、1つとして同じ環境状態は存在しない。そこで評価実験におけるデータ収集環境として、退室判定実験が十分に可能であり、周辺環境の異なる場所を選択し、以下に示す4種類の環境下で実験を行った。

表 1 各実験環境の詳細

	昼	夜
環境 A	室内外共に同じ程度の照度	室内外共に同じ程度の照度
環境 B	室内は明るく室外は暗い	室内は明るく室外は暗い
環境 C	室内に比べ室外の照度が高い	室内は明るく室外は暗い
環境 D	室内に比べ室外の照度が低い	室内は明るく室外は暗い

4.1.2 データ収集パターン

4種類の環境下で、成人男性5人に対して以下に示す2通りの行動の収集を行った。

パターン A

室内を歩き回る (1 分間) →退室 (約 5 秒間) →室外を歩き回る (1 分間)

パターン B

室内を歩き回る (1 分間) →静止 (約 5 秒間) →室内を歩き回る (1 分間)

各パターンにおいて3回ずつデータ収集を行った。

4.1.3 データ収集手法

我々は今回、部屋からの退出判定に用いるセンサデータとして加速度センサおよび、照度センサデータを選択した。そしてデータ収集のための携帯情報端末として Google NEXUS5 を使用し、Android 用データ取得アプリケーションソフトウェア「Sense-it」を用いて、加速度データおよび、照度データを収集した。各センサデータ取得間隔は 100Hz とした。携帯情報端末は図 1 のように、機器を横向きにして首からぶら下げ、照度センサ部分と画面が前を向くような状態で実験を行った。評価実験のためのデータの収集方法の詳細を表 2 にまとめる。

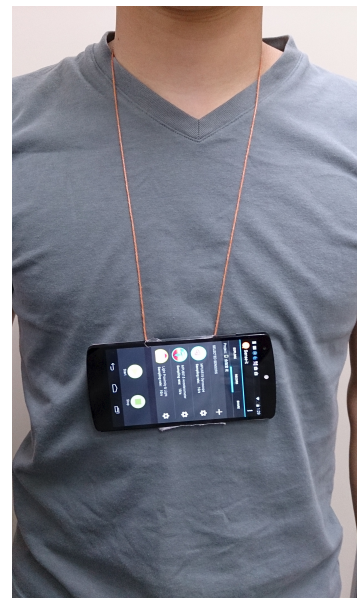


図 1 データ収集時の携帯情報端末の装着方法

表 2 データ収集方法詳細

使用端末	Google NEXUS5
アプリケーションソフト	Sense-it
端末取り付け位置	首 (ぶら下げ)
収集データ	加速度, 照度
サンプリング周波数	100Hz

4.2 特徴量抽出

収集した照度センサデータおよび加速度センサデータにおいて特徴量計算を行った。10秒ごとに時間窓を設定し、時間窓のずらし幅は1秒間隔として、設定した時間窓ごとに特徴量計算を行った。照度センサのデータにおいては平均値, 差分の和, 最大値, 最小値, 最大値と最小値の差を

計算し、特徴量とした。ここで述べた差分の和とは、時間窓内の最後の値から最初の値を引いた値である。一方加速度センサのデータにおいては、端末取り付けが固定されていなかったため3軸の2乗和平方を取り、分散を計算した。特徴量についてまとめた物を表3に示す。

表3 特徴量詳細

使用データ	照度, 加速度
時間窓幅	10 秒
時間窓ずらし	1 秒
照度データの特徴量	平均値, 差分の和, 最大値, 最小値, 最大値と最小値の差
加速度データの特徴量	3 軸の 2 乗和平方の分散

1 回分の実験で得られた収集データから計算した特徴量の個数は約 115 前後となった。

4.3 行動区間の抽出

計算した各特徴量の中から、それぞれの行動を機械学習用に抽出した。

パターン A の実験から得られた 1 回約 115 前後の特徴量のうち、退室中の行動が含まれている 55-65 秒の間の照度センサデータ特徴量を退室 (exit) データとしてラベル付けして抽出した。また、室内歩行中の行動が含まれる 20-30 秒の間の加速度センサデータ特徴量を歩行 (walk) データとしてラベル付けして抽出した。パターン B から得られた特徴量からは静止中の行動が含まれる 57-67 秒の間の加速度センサデータ特徴量を静止 (stay) データとしてラベル付けして抽出した。全特徴量データにおいて同じようにデータを抽出し、取得した特徴量データの総数は 3960 個となった。これらを、行動認識および退室判定に必要な学習用特徴量として用いる。

各実験パターン毎の収集データにおける時間と被験者の状態の関係を表4に、ピックアップした学習用特徴量とラベル、データ数の関係を表5に示す。

表4 各実験パターンの時間毎の行動/場所状態

取得時間	パターン A	パターン B
0-60(s)	歩行/室内	歩行/室内
60-65(s)	歩行/退室	静止/室内
65-125(s)	歩行/室外	歩行/室内

表5 学習用特徴量の概要

実験パターン	特徴量 No	ラベル	データ数
パターン A	55-65	退室 (exit)	1320
パターン A	20-30	室内歩行 (walk)	1320
パターン B	57-67	静止 (stay)	1320

4.3.1 評価方法

統計解析ソフト R 用いて機械学習を行い、提案手法の評価を行った。機械学習のための分類器として SVM (Support Vector Machine) を使用した。抽出した学習用特徴量を機械学習用に分割する手法として、今回我々は、以下に示す3通りの学習手法を考案した。

1-person-leave-out 学習

被験者毎にデータを分割し、学習用の被験者とテスト用の被験者が別々になるように学習を行う手法

1-place-leave-out 学習

実験環境毎にデータを分割し、学習用の被験者とテスト用の被験者が別々になるように学習を行う手法

1-person-place-leave-out 学習

被験者と実験環境がそれぞれ重複しないようにデータを分割し、学習用の被験者および実験環境とテスト用の被験者および実験環境が別々になるように学習を行う手法

1-person-leave-out 学習では、1 人の被験者をテストデータ、残りの全員の被験者を学習データとし、1-place-leave-out 学習でも、同じく 1 つの実験環境をテストデータ、残りのすべての実験環境を学習データとして、被験者および、実験環境を入れ替えていく形で重交差検証を行った。データの分割数から、1-person-leave-out 学習では 5 分割交差検定、1-place-leave-out 学習では 4 分割交差検定を行った。1-person-place-leave-out 学習では、1-person-leave-out 学習と 1-place-leave-out 学習を組み合わせた形で、20 通りの組み合わせについて交差検定を行った。

それぞれの学習手法において、歩行の判別精度、退室の判別精度および、歩行と退室の両方を取った場合の判別精度の 3 つを導き評価した。

4.4 結果

提案手法を用いた解析結果を述べる。

4.4.1 特徴量

収集したデータから各特徴量を計算した。1 回の実験ごとの特徴量の流れをグラフ化したものの一部を図2、図2に示す。図2に示した2つの照度特徴量グラフは、どちらも昼の時間帯、環境 D、同じ被験者という条件であるが、上が実験方法のパターン A、下がパターン B におけるものである。照度の生データが raw、5 つの特徴量はそれぞれ平均値を mean、差分の和を diffsum、最大値を max、最小値を min、最大値と最小値の差を minmax で表している。パターン A においては退室後の各照度特徴量に明らかな変化が見られるが、パターン B においては退室時に特徴量に若干の変化が見られるくらいで退室前と退室後ではあまり変化が見られない。

このような照度特徴量の変化は室内、退室、室外における行動による照度変化によるものであると考えられる。この他の照度特徴量グラフにおいても環境や時間帯、被験者、実験パターンによって違った結果が得られた。




図 2 昼、パターン A の照度特徴量

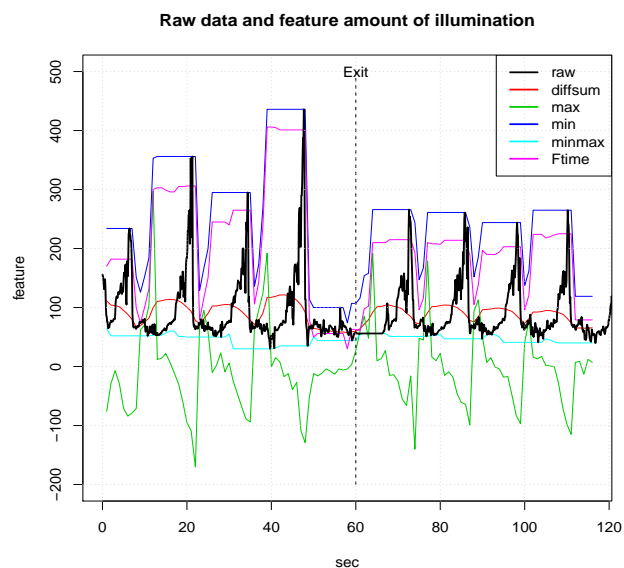


図 3 昼、パターン B の照度特徴量

4.4.2 機械学習による判別結果

まとめた全特徴量データから、機械学習を行い、判別精度を検証した。第 4.3.1 項に示した 3 つの学習手法を用い、歩行の精度、退室中の精度および、歩行と退室中の両方を取った場合の判別精度の 3 つを導きだした。今回の実験で精度を求めた式を以下に示す。

$$\text{精度} = \frac{\text{予測結果の正解件数}}{\text{特徴量データの合計件数}} \times 100 \% \quad (1)$$

これ以降、精度は上記の式により求めた結果とする。

1-person-leave-out 学習の結果

被験者毎に学習用特徴量を分割し学習を行う。1 人の被験者の各特徴量データをテストデータ、ほかの 4 人被験者の各特徴量データを学習データとして 5 分割交差検定を行った。歩行の判別結果を図 6、退室の判別結果を図 7、歩行かつ退室の判別結果を図 8 にそれぞれ示す。以下は、列方向が正解、行方向が予測を示している集計表である。

表 6 歩行の推定精度

正解 \ 推定	静止	歩行
静止	544	776
歩行	165	2475
精度		76.23[%]

表 7 退室の推定精度

正解 \ 推定	静止	歩行
静止	2477	163
歩行	252	1068
精度		89.52[%]

表 8 歩行かつ退室の推定精度

正解 \ 推定	退室以外	退室
室内歩行	1210	110
静止	1279	41
退室	340	980
精度		87.60[%]

機械学習の結果、歩行のみの判別精度は 76.23 %、退室のみの判別結果を 89.52 %、歩行と退室の両方を取った場合の判別結果は 87.60 % という結果となった。判別結果は他の 2 つの学習手法に比べ高い精度が得られた。

1-place-leave-out 学習の結果

実験環境毎に学習用特徴量を分割し学習を行う。1 つの実験環境の各特徴量データをテストデータ、ほかの 3 つの実験環境の各特徴量データを学習データとして 4 分割交差検定を行った。歩行の判別結果を図 9、退室の判別結果を図 10、歩行と退室の両方を取った場合による判別結果を図 11 にそれぞれ示す。

表 9 歩行の推定精度

正解 \ 推定	静止	歩行
静止	553	767
歩行	166	2474
精度		76.44[%]

表 10 退室の推定精度

正解 \ 推定	静止	歩行
静止	2173	467
歩行	463	857
精度		76.52[%]

表 11 歩行かつ退室の推定精度

正解 \ 推定	退室以外	退室
室内歩行	1093	227
静止	1157	163
退室	531	789
精度		76.74[%]

機械学習の結果、歩行のみの判別精度は 76.44 %，退室のみの判別結果を 76.52 %，歩行と退室の両方を取った場合の判別結果は 76.74 % という結果となった。

1-person-place-leave-out 学習の結果

被験者および実験環境毎に学習用特徴量を分割し学習を行う。1つの実験環境毎に5人の被験者がデータ収集実験を行っているため、1人の被験者が1カ所の実験環境で得た各特徴量データをテストデータ、ほかの19の各特徴量データを学習データとして交差検定を行った。歩行の判別結果を図12、退室の判別結果を図13、歩行と退室の両方を取った場合の判別結果を図14にそれぞれ示す。

表 12 歩行の推定精度

正解 \ 推定	静止	歩行
静止	544	776
歩行	180	2460
精度		75.86[%]

表 13 退室の推定精度

正解 \ 推定	静止	歩行
静止	2156	484
歩行	471	849
精度		75.88[%]

表 14 歩行かつ退室の推定精度

正解 \ 推定	退室以外	退室
室内歩行	1079	241
静止	1155	165
退室	534	786
精度		76.26[%]

機械学習の結果、歩行のみの判別精度は 75.86 %，退室のみの判別結果を 75.88 %，歩行と退室の両方を取った場合の判別結果は 76.26 % という結果となった。1-place-leave-out 学習結果および 1-person-place-leave-out 学習結果の精度はほとんど変わらない結果となった。

5. 考察

提案した3つの学習手法で解析を行った結果、もっとも高い判別精度を得られたのは 1-person-leave-out 学習を用いた場合であることが分かった。1-person-leave-out 学習の結果に比べると、他の2つの学習手法は高い結果ではなかったが、3つすべての学習手法で 75 % を超える判別精度を得ることができた。本章では各手法による学習の結果と、その結果を踏まえ、今後の課題を考察する。

3つの学習手法を用いて、歩行、退室、歩行かつ退室についてそれぞれ判別を行った。今回の提案手法の1つである、退室判定のために歩行と退室の両方を取り、どちらも真である場合を判別する手法の精度は、1-place-leave-out 学習、1-person-place-leave-out 学習に関しては、歩行のみ、退室のみの判別方法に比べわずかながら高い結果が得られたが、特別高い精度を得ることはできなかった。また、1-person-leave-out 学習に関しては、退室のみを判定したほうが高い結果となった。そして、3つの学習手法どれにおいても、歩行の判別精度が最も低い結果となった。歩行の判別精度が低いと、歩行していると判断されたデータの中から、退室を判別するといった手法の場合に精度に大きな影響を与えてしまうこともあり、より高い判別精度が求められる。今回、歩行と退室の両方を取り、判別する手法の精度が他とあまり変わらなかった理由も、材料の1つである歩行の判別精度が低かったためであると推測される。歩行の判別精度が最も悪かった理由として携帯情報端末の装着法に原因があるのではないかと考えられる。首からぶら下げて装着する方法だと、ポケットなどに入れて固定して測定する場合に比べて大きく不規則に端末が動いてしまうためにデータに影響が出ることがあるためである。今後は装着方法を見直し、首から下げるだけでなく、服に軽く固定するなどの方法を検討していく。また、特徴量の選択や時間窓、ずらし幅の値の違いなどでも、判別精度に影響してくるため、さらに考察しなければならない。

1-person-leave-out 学習結果は退室のみの判定精度が 89.52 %，歩行かつ退室での判別精度が 87.60 % と、最も高い結果となった。1-place-leave-out 学習および 1-person-place-leave-out 学習においては、歩行、退室、歩行かつ退室のどれも精度 76 % ほどであり、1-person-leave-out 学習の結果と比べ精度が低かった。この結果から、退室判定において被験者による影響よりも実験環境による影響のほうが大きいということが分かった。外部の環境に左右されやすいことから、今後は環境設定を、より増やして実験を行っていく必要がある。今回は検証を行わなかったが、昼と夜で分割して学習する必要もあるだろう。

6. まとめ

本稿では、携帯情報端末の MEMS センサを用いて収集し

た加速度および照度センサデータによって部屋からの退室判定を行うための手法を提案し、1-person-leave-out 学習、1-place-leave-out 学習、1-person-person-leave-out 学習結果の3つの学習手法から、退室の判別精度について検証を行った。各学習手法で歩行と退室の両方を取った場合の判別結果は、1-person-leave-out 学習では 87.60 %、1-place-leave-out 学習では 76.74 %、1-person-person-leave-out 学習では 76.26 % の判別精度を得ることができ、1-person-leave-out 学習においては特に高い精度が得られた。しかしながら、退室判定に重要な歩行の判定精度については、端末の装着方法や特徴量計算に工夫を加えるなどして、さらに精度を上げていく必要がある。歩行判定の精度を上げることによって、歩行と退室の両方から判別する手法のさらなる精度向上を目指す。また、被験者の違いよりも周囲の環境変化が大きく影響していることが分かったため、環境パターンを多く設定して精度を検証していく。

今後検証実験を重ねていくうえで、より多くのデータが必要となってくる。そこで、より簡単にデータ収集が可能な手段の発見や、アプリケーション等の開発にも力を入れていきたい。そして、将来的にはリアルタイムで退室判定が行えるように研究を進めていく。

謝辞

本研究の一部は、基盤研究 (B) 「物理層と意味層の2階層からなるセンサコンテキスト推定技術 (研究代表者: 井上創造)」による。

参考文献

- [1] 服部祐一, 竹森正起, 井上創造, 平川剛, 須藤修, “携帯情報端末による大規模行動収集システムの運用と基礎評価”, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2010) 予稿集, pp.583 - 590, July 6, 2010, Gifu, Japan.
- [2] 服部祐一, 竹森正起, 井上創造, 平川剛, 須藤修, “携帯情報端末による大規模行動情報収集システム「ALKAN」”, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO2010) 予稿集 (デモ), pp.2061 - 2065, July 6, 2010, Gifu, Japan.
- [3] “HASC - Human Activity Sensing Consortium”, <http://hasc.jp/>.
- [4] Yuichi Hattori, Sozo Inoue, Go Hirakawa, Osamu Sudo. “Gathering Large Scale Human Activity Information Using Mobile Sensor Devices”, International Workshop on Network Traffic Control, Analysis and Applications (NTCAA-2010), pp.708-713, Fukuoka, Japan, 2010.
- [5] 納谷 太, 大村 廉, 野間 春生, 小暮 潔, “センサネットワークを用いた業務の計測と分析”, Information Processing Society of Japan, (2009)
- [6] 野原康伸, 井上創造, 中島直樹, 上田修功, 喜連川優, “A Large-scale Sensor Dataset in a Hospital”, International Workshop on Pattern Recognition for Healthcare Analytics, 4pages, November 11, 2012, Tsukuba.
- [7] 中村 優斗, 井上 創造, 野原 康伸, 中島 直樹, “Finding Nursing in the Room from Accelerometers and Audio on Mobile Sensors”, IUI Workshop on Location Awareness for Mixed and Dual Reality (LAMDA), pp. 17-20, March 19, 2013, Santa Monica, USA.
- [8] 井上 創造, “スマートフォン行動情報収集と看護行動センシング (Smartphone Activity Data Collection and Nursing Activity Sensing)”, 情報処理学会誌, Vol. 54, No. 6, pp. 600-604, May 15, 2013.
- [9] 右田 尚人, 服部 祐一, 田中 翔太, 井上 創造, “動画像と加速度データを用いた行動類似度評価システム MimicMotion の開発と評価 (Development and Evaluation of Behavioral Similarity Evaluation System MimicMotion Using Acceleration Data and Video)”, マルチメディア, 分散, 協調とモバイル (DICOMO2013) シンポジウム, pp. 1207-1216, July 10, 2013, Tokachi, Hokkaido.
- [10] 弓山 卓哉, 右田 尚人, 井上 創造, “ベイズ推定を用いた加速度センサからの人物姿勢の推定に向けて (Toward Estimation of Human Postures from an Acceleration Sensor Using Bayesian Estimation)”, 第 15 回 SOFT 九州支部学術講演会, pp. 129-130, December 21, 2013, Shimonoeki.
- [11] 三菱電機, “三菱統合ビルセキュリティシステム, ハンズフリー入退室管理システム”, <http://www.mitsubishielectric.co.jp/building/security/hands-free/>
- [12] Chih-Chung Chang, Chih-Jen Lin, “LIBSVM-A Library for Support Vector Machines” <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>