

プライバシーに配慮した屋内行動モニタリングシステムの提案

An Indoor Human Behavior Monitoring System with Due Consideration for Privacy

岡田遼太郎
Ryotaro Okada

矢入郁子
Ikuko Yairi

上智大学院理工学研究科理工学専攻情報学領域
Graduate Schools of Science and Technology, Sophia University

Purpose of this study is to enable to get persons' behavioral data in private space for investigating the actual situations, such as lifestyles of blind people that are not well known. In this study we use infrared array sensors that is superior to cameras in privacy issue. To estimate persons' situations from data of infrared array sensors, we use Support Vector Machines for classifications.

1. はじめに

現代の情報化社会ではビッグデータが大きな注目を浴びており、移動や購買などの多様な行動データが収集・利用されている。しかし、人のプライベート空間での行動データはプライバシーを侵害する恐れがあるため、収集・利用が困難な場合がある。そこで、本研究では人の屋内位置情報をプライバシーに配慮した赤外線アレイセンサを用いて収集することで、カメラによるモニタが不可能だったプライベート空間のデータ収集をも可能とし、例えば一人で生活している視覚障害者の生活実態や、病棟での看護者と被看護者の行動実態などを明らかにすることを目的としている。赤外線アレイセンサの温度データからの行動推定には、教師付き機械学習であるサポートベクターマシン(SVM)による分類を用いる。

2. 屋内位置モニタリングシステム

2.1 赤外線センサを用いたモニタリング

近年では屋内位置情報の取得に関する研究が盛んであり、カメラ、RFID、無線 LAN、赤外線、超音波といった様々なデバイスが位置推定に用いられている[Koyuncu *et al.*, 2010]。屋内における人の位置推定に関する研究は多いが、それを踏まえて屋内における人の行動の推定に及ぶ研究はなされていないのが現状である。本研究は単なる見守りシステムにとどまらず、知られざる人の行動実態を積極的に明らかにすることを目的としている。人間行動認識には大別して三つの手法があり、それらはカメラによる動画ベースのもの(VSAR)、ウェアラブルなセンサベースのもの(W SAR)、様々なオブジェクトを利用したもの(OUAR)である[Guan *et al.*, 2011]。この中で OUAR は他の二つに比べ新しい手法で、それらの限界を超えるために提案されたものであり、本稿ではこの手法を用いる。VSAR のように生活にカメラが介入することは人々にとって不快なものであり、プライバシーを侵害する可能性が高い。また W SAR はセンサを着用することを好まない人がいることや、着用を忘れる可能性といった懸念事項が存在する。

以上を踏まえ、オブジェクトとしてプライバシーを侵害することがなく、かつ屋内における人の位置推定に必要な精度を持つという二つの点を満たしている、赤外線センサを用いて屋内位置

推定を行う。赤外線センサで得る情報は抽象度が高く、カメラの画像によるものと比べてプライバシーを侵害しにくい。また、ノイズによる影響が少なく、設置場所を選ばないことも赤外線センサの有利な点である。赤外線は電波などを発して情報を取得する他のセンシング方法とは異なり、人の赤外線を吸収するのみなので、人体の健康への影響がないことも不特定多数の人のデータを収集する上でメリットである。本研究の位置推定方法としては、屋内における床面上の位置を二次元の有限個の座標に区切り、それぞれの座標における温度差を用いて人のいる場所を推定する方法を用いる。

2.2 赤外線アレイセンサを用いたデータロガー

本研究では様々な場所におけるデータ収集を行うため、取り付けが容易なデータロガー(図1)を作成した。赤外線センサとして、赤外線アレイセンサの Grid-Eye(図2)を用いた。このセンサは一つあたり 8×8 (64 画素)の素子を持ち、それぞれの画素をそのまま人の屋内位置座標として温度値を収集することができるため、容易に本研究における位置情報取得が可能である。このセンサと microSD カードリーダー・ライターを組み合わせ、温度値を随時記録する。センサと microSD カードの入出力制御はマイコンボードの Arduino Uno を用いる。電源は 9600mAh のバッテリーから供給する。データロガーの動作としては、バッテリーの電源を入れると Arduino Uno が起動し、Grid-EYE からの温度データを microSD カードに随時書き込むというものである。バッテリーの電源を切ることによってデータロガーは動作を停止する。Arduino Uno には電源を入れてからの経過時間を随時計算するプログラムが入れてあり、電源を入れてから初めて Grid-EYE の温度データを書き込むのは電源を入れてから1秒後、以降 0.5 秒おきに逐次温度データを記録していく(フレームレートは 0.5fps)。フレームレートは、Arduino Uno が Grid-EYE からの温度データ入力、及び microSD カードへの書き込みを行うにあたって、安定して動作できる最速の時間で設定したものである。教師データのラベル付けに用いるビデオカメラとの同期は、データロガーの電源を入れた瞬間と、電源を切る瞬間の時間を用いて行う(電源を入れてから 1 秒後に温度データの書き込みが始まるため、補正を行う)。このデータロガーで生成するファイルは、温度値がカンマで区切られているテキストファイルである。温度値は摂氏の 4 倍の整数値で記録される(つまり、温度精度は 0.25°C となる)。このデータロガーを複数個部屋の天井に設置し、長期間に及ぶ人の行動データ収集を行う。開発環境として、Arduino Uno による赤外線アレイセンサからの温度データ入力、microSD への書き込み・読み込み、及びそれらのタイムマネジメントには Arduino IDE、データロガーで生成された

連絡先: 岡田遼太郎, 上智大学大学院理工学研究科理工学専攻情報学領域, 102-8554, 東京都千代田区紀尾井町7-1, okada@yairilab.net

データの読み込み, 温度データのグラフィカルな表示には MATLAB, SVM による機械学習には LIBSVM を用いた。




図1 作成したデータロガー




図2 赤外線アレイセンサ Grid-Eye

3. 実験

本研究では, 作成したデータロガーを屋内の天井に下向きに取り付け, 人の位置を温度データとして取得する. サンプルレートは 10fps, 温度の分解能は 0.25°C である. 赤外線アレイセンサの視野角は 60° で, 天井に取り付けた場合, データロガー一台あたり八畳ほどの温度センシングが可能である. この Grid-Eye の視野角と, 今回の実験を行う部屋の高さからセンシング可能な範囲を計算したところ, 一台につき今回の実験場所では 346cm 四方ほどの検出が可能であることがわかった. この実験の被験者(屋内位置を推定される人)は, 特に指定しない人数名(出入りした人物は計8名, 部屋の中にいる人数は最大で3名)である. また, 取得したデータをもとに, 機械学習の代表的な手法であるサポートベクターマシン(SVM)を用いて特徴検出を試みる. 屋内における時系列の温度データには, 部屋のなかにいる人の人数や, 人の場所や移動軌跡など様々な屋内行動・状況が表れ, 多様な特徴抽出が可能であると考えられる. [Xing et al., 2010]に記載されている通り, SVM は時系列データ分類において有効な手法であり, さまざまな研究分野で利用されている[Kim et al., 2009; Xue et al., 2010]. SVM は教師付き学習機であるため, 正解情報が既知である必要がある. 本研究ではデータロガーによる情報収集と同時にビデオカメラで動画を撮影することで, 正解データを作成する. ビデオカメラで撮影した動画と, 赤外線アレイセンサの時系列温度データを同期させるため, それぞれの記録開始・終了を同時刻に行い, データロガー側の記録フレーム数をビデオカメラの記録時間で割ってそれぞれを対応させる方法をとった. ビデオカメラは実験場所の入口付近に三脚を用いて設置し, Grid-EYE のセンシング範囲が全て映るようにした. 実験は全部で3日(それぞれ実験1~3), 人の出入りが多い状況で, 部屋の所有者以外には実験であることを説明せず, 実験時間はそれぞれ2時間~4時間, 一般的な日常行動データを得ることができた.

4. 収集したデータの特徴

以下の図4は今回の実験場所におけるデータロガー一台分のデータの数フレーム分の取得温度値の例である. 赤いところが高い温度を, 青いところが低い温度を表している. この画像では, 特に温度の高いところが二箇所確認できるが, そのうち左上の部分が人のいる場所, 右下の部分は PC の置いてある部分

である. 人の部分付近は温度値が変動しており, PC の部分は温度値が変動していないことがわかる. つまり, 部屋の中にある可能性の高いこういった発熱体があっても, 人と区別することが可能である可能性がある.

収集した Grid-EYE の温度データを見てみると, 同じ室内であっても, それぞれの Grid-EYE ごとに温度値の平均値(全ての画素の温度値の平均)が上下していることがわかった. また, 温度値が常に高い画素がある場合もあった. これらは, センサの特性にばらつきがあるためであると推測される. なお, 温度の平均値は Grid-EYE の個体ごとに異なっているが, それぞれの Grid-EYE の平均温度値からの温度変化の幅は概ね同じであった. 実験1~3においては全て同じデータロガーを用いて測定を行ったが, それぞれの実験から得られた温度データの平均値が大きく異なっていた. 実験1の温度データの平均値は 18.31°C, 実験2の温度データの平均値は 23.97°C, 実験3の温度データの平均値は 23.37°C である. 実験ごとの人数や行動によって温度データによる差異が生じることを考慮しても, 特に実験1と実験2および実験3を比較したときの温度データの平均値の差異は大きい. この理由としては, 実験によって室温が異なっていた可能性が考えられる.

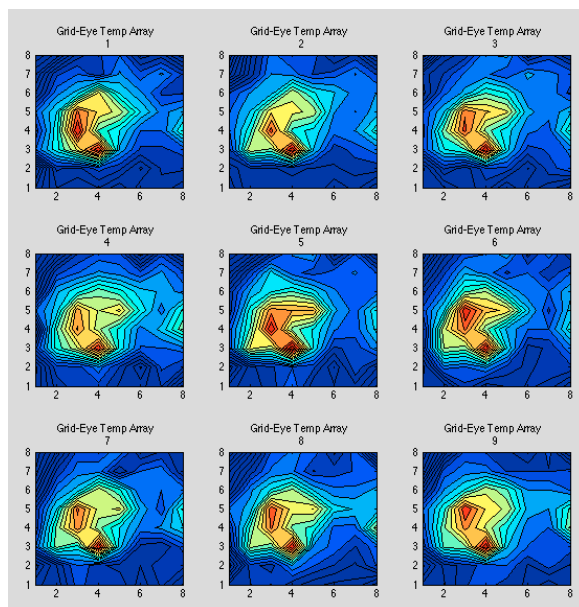


図4 取得した温度データ

(9フレーム分, 机で人が PC に向かって作業している様子. 二段目中央では人が左手を伸ばしている様子わかる)

5. 機械学習による分類

5.1 教師データの作成

教師データ作成にあたり, Grid-EYE の各フレームの温度値群に対応したラベル付けを行い, 行動を分類させる必要がある. 今回使用する Grid-EYE の温度データのみを参照では, 行動を類推することが困難であるため, 教師データ作成の際にはデータロガーの記録と同時に録画したビデオカメラによる動画を利用した. この際, ビデオカメラによる動画と Grid-EYE を搭載したデータロガーによる温度データを時間的に同期させる必要がある. 今回用いる方法は, Arduino Uno に内蔵されている時計プログラムの精度が比較的良好いため, データロガーの記録開始時間を基準として同期する方法をとる. データロガーの電源を入れる瞬間をビデオカメラで録画し, ビデオカメラの動画側の基準

を合わせる。念のため、データロガーの記録終了のタイミング(電源を切るタイミング)もビデオカメラで録画し、データロガーに記録された総フレーム数と、ビデオカメラ総録画時間を対応させて、誤差を比較した。その結果、今回の実験での平均フレーム数誤差は一時間あたり2~3フレーム(時間にすると1~1.5秒)に収まった。本研究では一度に二種類のみ分類を行う。

5.2 人数による分類

部屋内(設置した部屋内の Grid-EYE がセンシングできる範囲内)にいる人数を、SVM(Support Vector Machine)による機械学習で分類を行った。振り分け方は「誰もいない場合と、それ以外」「一人だけいる場合と、それ以外」「二人だけいる場合と、それ以外」のように、二通りずつ行った。また、正しい分類を行うためには、その分類が行われる基準を正確にする必要がある。今回の人数の振り分けに関しては、部屋内に一定の基準線(センサがカバーできる領域の境目)を設け、そこから内側(データロガーがある側)の領域に完全に体が入っている人を人数としてカウントした。以下に、実験場所における三回の実験のそれぞれの人数の分類結果の精度を示す(表1)。

表1 人数の分類結果の精度(%)

	0人	1人	2人
実験1	99.5868	98.4765	99.2081
実験2	98.8034	98.3195	99.9738
実験3	99.1887	94.9735	95.3633

次に、それぞれの実験の分類対象について学習したデータを用いて、別のもう一つの実験のデータについて予測分類を行った。しかし、この結果では実験データの組み合わせ方によって精度に大きな差が出ていた。特に実験1の温度値を予測分類する際の精度が著しく低い。この理由として、実験1で収集した温度データの平均値が実験2及び実験3の温度データの平均値よりかなり低いため、実験2及び実験3を用いた学習で生成されたサポートベクトルの閾値より実験1の温度データの低い温度値がすべて低いものとして分類されてしまい、精度が下がっていることが考えられる。そのため、対策として全ての実験データの温度値の平均を合わせる作業を行って、再度分類を行うことにした。平均を合わせる方法としては、今回の3実験中で温度データの平均値が中央値となっている実験3の温度データの平均値を基準として、実験1及び実験2の全ての温度データに差分を足し引きすることとする。以下の表2~表4に、それぞれの実験から得られた温度データ値の平均値を合わせた操作の後の、学習データに用いた実験と、その学習データを用いて予測分類を行った実験の組み合わせに対する分類精度を示す。

表2 実験1の学習データを用いた人数予測分類精度(%)

	実験2	実験3
0人	96.1028	97.9876
1人	94.6838	64.4427
2人	99.9085	66.4234

表3 実験2の学習データを用いた人数予測分類精度(%)

	実験1	実験3
0人	99.5868	98.4
1人	97.6568	65.177
2人	99.1694	66.4008

表4 実験3の学習データを用いた人数予測分類精度(%)

	実験1	実験2
0人	99.3329	91.107
1人	97.8568	94.4942
2人	99.9601	99.8954

5.3 行動による分類

部屋内(設置した部屋内の Grid-EYE がセンシングできる範囲内)にいる人の行動を、SVM(Support Vector Machine)による

機械学習で分類を行った。前章と同じ理由から、一度の分類で二種類に区別する。今回取り上げる行動としては、センサ内にいる特定の人(対象は一名のみ)が椅子に座ったかどうかで分類する。分類基準は、対象人物が椅子の座面に触れた瞬間、及び離れた瞬間としている。以下に、今回の実験場所における三回の実験それぞれの分類結果の精度を示す(表5)。

表5 座る行動の分類結果の精度(%)

実験	精度(%)
実験1	98.5884
実験2	98.9865
実験3	99.2159

次に、先ほどの人数の分類の場合と同様に、それぞれの実験の分類対象について学習したデータを用いて、別のもう一つの実験のデータについて予測分類を行った。しかし、先ほどの人数分類の場合と同様に、実験データの組み合わせ方によって精度にかなり大きな差が出ていた。そして特に実験1のデータが絡んでいる行動分類の精度が著しく低い。そのため、先ほどの人数分類のときと同様に、それぞれの実験から得られた温度データ値の平均を合わせる作業を行い、再度行動の分類を行った。以下の表6に、それぞれの実験から得られた温度データ値の平均値を合わせた操作の後の、学習データに用いた実験と、その学習データを用いて予測分類を行った実験の組み合わせに対する分類精度を示す。

表6 それぞれの実験データの学習・予測対象の組み合わせによる予測分類精度(行:学習データ, 列:予測対象, 単位%)

	実験1	実験2	実験3
実験1	-	92.4148	96.8726
実験2	85.006	-	98.1553
実験3	97.9558	93.2037	-

6. 考察

6.1 各データの特徴

実験1~実験3の温度データを比較すると、それぞれの実験において同じ Grid-EYE を用いたデータロガーでデータ収集を行ったにもかかわらず、温度データの平均値に大きな差異が生じていることがわかる。このことは、Grid-EYE の個体差ではなく、実験ごとに何らかの変化があるために生じた温度の差異であると考えられる。その理由として考えられることの一つに、実験によって室温が大きく違った可能性がある。実際にそれぞれの実験データを図示して比較してみると、実験1のデータだけ温度値が他の実験データに比べて著しく低いことがわかった。このことを踏まえ、それぞれの実験の温度データの差異をなくすために、それぞれの実験の温度データに数値を足し引きする作業を行った。この操作を行った後の実験1の温度データは、他の温度データと比べても遜色ないことが確認できた。つまり、温度データ値が極端に高かったり低かったりするのではなく、全体的に値が異なっていることが予測される。

6.2 分類結果に対する考察

本実験の特徴の一つとして、実験ごとに部屋への人の出入り方や行動の仕方に大きなばらつきがあることが挙げられる。このことによって各実験データの記録全体に対する分類対象の行動の占める割合が異なるため、それぞれの実験での分類の精度が変わる原因の一つになると考えられる。このような現象は実際のプライベート空間で用いる場合も同じ条件であり、どのような行動パターンにおいても高い精度で分類が可能であることは、このシステムを他の場所や被験者を対象にしても応用可能であると言える。学習データからの未知データの分類予測について、それぞれの実験データを学習データと未知データに

割り当てたところ、組み合わせ方によって予測の精度に大きなばらつきが出た。学習データがサポートベクトルによって分類される精度が良い場合、及び分類対象の未知データそのものも同じく学習データとして分類した場合にサポートベクトルによって精度良く分類される場合、高い精度で未知データの予測分類ができていく傾向が見られる。そのため、更なる未知データの分類精度向上のためには、それぞれの温度データに対応したラベル付けをより正確に行う必要がある。実験3を行っていた際は実験1, 2とは異なり、人が最大で3人いる場合があった。そのため、分類結果に誤りが生じて精度が落ちてしまったことが考えられる。そのことに加え、実験3では実験1, 2ではなかった、人数が二人の状態でも席を立ったり座ったりするという動作があった。このことから、学習データには様々な行動パターンが入っていることが、状況を分類するために必要なことがわかる。そのことを裏付けることとして、実験1, 2のデータを用いて、それらに含まれない様々な行動パターンを含む実験3のデータを予測分類する際は精度が低くなっていたのに対し、様々なパターンを含む実験3のデータをもとに他の実験データを分類する際は、精度が良くなっていた。具体的には、前者の場合では「部屋内の人数が1人」「部屋内の人数が2人」という分類を行った場合に精度が64~66%ほどであったのに対し、後者の場合では、全ての分類において精度が92.4148%以上、平均すると97.1845%の分類精度が得られた。また、特殊な場合(人数が3人になったり、人数が2人の状態で席を立ったり座ったりする状況になったりしていない)を含まない実験1と実験2の間での相互分類では、精度が全ての場合で92.4148%以上、97.2136%の分類精度が得られた。椅子に着席しているか否かの行動分類と、人数が0人の場合の行動分類の精度は、実験1~3のどの組み合わせにおける分類においても、精度に大きな差異は見られなかった。このことから、屋内で機械学習による分類を考慮した場合、教師データとしては、多様な行動パターンが網羅されているものを用意することが望ましいということがわかった。

6.3 目的に対する考察

本研究は人のプライベート空間での屋内行動をモニタリングすることが目的であるため、プライバシーを侵害しないということが第一条件である。実験を行った際、センサの範囲内にいた人に聞き取り調査を行った結果、全ての人が「全く気にならなかった」とのことであったので、プライバシーに対する問題はないと言える。一方、屋内行動モニタリングシステムという点では、まだまだ行動分類が不足している。より多彩な行動を正確に分類し、何らかのフィードバックとしてユーザに情報を提供するシステムが求められる。

6.4 将来課題

今回行った実験で得られたデータはそれぞれの行動パターンの量にばらつきが多く、またSVMの学習モデルとして十分な種類の行動パターンが網羅されていないために精度が落ちてしまった場合があった。本実験では少数かつ多様な行動状況(例えば、部屋に出入りする人数を全て想定すること、部屋内にいる人数それぞれの場合に対し人が座る、立つなどの特定行動が起こること)を意図的に再現することが容易なため、学習モデル形成の際は、そのような状況をより多く学習させ(Over Sampling), より精度の高い分類を行うことが望まれる。

本研究で行った機械学習の分類において、今回行ったデータロガーで記録した温度データを用いた方法では、分類に向き不向きがあることがわかった。人数の振り分けは本稿の提案手法でも高い精度が得られるが、特定の行動が起きたときの分類

は、データロガーによる温度データからでは推定が難しい。このことを踏まえてさらなる行動の多様な分類とその精度を得るために、Grid-EYEのような赤外線センサだけでなく、例えばスマートフォンの加速度センサを用い、特定行動時の特徴を捕えられるようにし、赤外線センサによるデータと統合して分析できるようにしたい。また今後、リアルタイムに屋内行動をモニタリングするために、ハードウェア面をより工夫し、随時データの受け渡しを行える仕様にする予定である。そのための例として、データロガーではなく、収集したデータを無線デバイスで送信することが挙げられる。

近年ではクラウドコンピューティングが盛んであり、本研究も最終的な目標としてはサーバーでデータを集積し、よりスケールの大きいデータ収集・分析、及びWeb上での多彩なサービスを提供していきたいと考えている。そのためリアルタイムな処理を実現するために、他のアルゴリズムを用いたデータ処理が望まれる。例えば、Optical Flowを用いたフレーム間でのデータ分析などを用いることで、さらなる行動モニタリングが可能になると予想される。

7. おわりに

現代の情報化社会ではビッグデータが大きな注目を浴びており、まだ利用されていない種類のデータ収集・及び利用の可能性を考え、本研究ではその一例として人のプライベート空間での行動データを取り上げた。この行動データを収集・利用するために、プライバシーに配慮した赤外線アレイセンサを用いたデータロガーを作成し、研究室における実験で実際に行動データを収集、教師付き機械学習であるサポートベクターマシン(SVM)による分類によって屋内行動をモニタリングできる可能性を示した。今後の課題としては、より多くの場所におけるデータ収集および分析、リアルタイムなサービスを可能にするためのアルゴリズムの利用が挙げられる。それらの技術を用い、サーバー上に多くの人の屋内行動データを集め、サービスとしての屋内行動モニタリングシステムを構築することが、本研究の最終目標である。

謝辞

本研究は(財)テレコム先端技術研究支援センター(SCAT)の助成により実施されました。

参考文献

- [Koyuncu et al., 2010] H. Koyuncu, Shuang Hua Yang. A Survey of Indoor Positioning and Object Locating Systems. IJCSNS International Journal of Computer Science and Network Security, vol.10, pages 121-127, 2010
- [Guan et al., 2011] D. Guan, et al. Review of Sensor-based Activity Recognition Systems. IETE Technical Review, vol.28, pages 418-433, 2011
- [Xing et al., 2010] Z.Xing, J.Pei, and E.Keogh. A brief survey on sequence classification. ACM SIGKDD Explorations Newsletter, vol.12, pages 40-48, 2010
- [Kim et al., 2009] Y.Kim, et al. Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine. IEEE Transactions on Geoscience and Remote Sensing, vol.47, pages 1328-1337, 2009
- [Xue et al., 2010] Z.Xue, et al. Infrared gait recognition based on wavelet transform and support vector machine. Pattern Recognition, vol.43, pages 2904-2910, 2010