

手に装着した磁気センサによる電化製品の利用の認識

前川 卓也^{†1} 岸野 泰恵^{†1}
櫻井 保志^{†1} 須山 敬之^{†1}

本稿では、デジタルカメラや携帯電話、電動髭剃り、電動歯ブラシといった携帯型電化製品から発せられる磁場を、手に装着した磁気センサにより計測することで、ユーザが使用している電化製品を認識する手法の提案を行う。現代社会では、われわれは数多くの電化製品に囲まれて暮らしているため、それらの利用を検知することで、ユーザの高度な行動の認識を行うことができると考えられる。そのため、電化製品に添付したユビキタスセンサによるモニタリングや、家庭内の電気系統のモニタリングなどのアプローチを用いて電化製品の利用を検知・認識する研究がこれまでに数多く行われている。本稿で提案する手法は、家庭の電気系統に接続していない携帯型電化製品の利用を、電化製品に直接添付したユビキタスセンサなしに認識することを特徴とする。本稿では、実家庭環境において提案手法の認識精度の評価を行い、手に装着した少ない数の磁気センサで高い精度の認識を達成した。

Recognizing Use of Electrical Devices using Magnetic Sensors Attached to Hands

TAKUYA MAEKAWA,^{†1} YASUE KISHINO,^{†1}
YASUSHI SAKURAI^{†1} and TAKAYUKI SUYAMA^{†1}

The method proposed in this paper recognizes the use of portable electrical devices such as digital cameras, mobile phones, electric shavers, and electrical toothbrushes with hand-worn magnetic sensors by sensing the magnetic fields emitted by these portable devices. Because we live surrounded by large numbers of electrical devices in modern societies and frequently use these electrical devices, we can estimate our high-level daily activities by recognizing the use of electrical devices. Thus, many studies have tried to detect/recognize the use of electrical devices by using such approaches as ubiquitous sensing and infrastructure-mediated sensing. A feature of our method is that we can recognize the use of electrical devices that are not connected to the home infrastructure without the need for any ubiquitous sensors attached to the devices. We evaluated the performance of our recognition method in real home environ-

ments, and confirmed that we could achieve highly accurate recognition with small numbers of hand-worn magnetic sensors.

1. はじめに

行動認識技術は、高齢者の見守りや運動の記録といった、ライフログアプリケーションやコンテキストウェアシステムを実現するための基盤的技術の1つである。行動認識のアプローチは、身体に装着したセンサ(ウェアラブルセンサ)を用いるものと、環境に設置したセンサを用いるものの2つに大まかに分けられる。ウェアラブルセンサによる手法では、身体に装着した加速度センサやマイクなどから取得したセンサデータを用いて行動の認識を行う^{1),9),10),12)}。環境に設置したセンサによる手法では、大量のRFIDタグやスイッチセンサなどのユビキタスセンサを日常物に添付し、日常行動を観測することが多い^{15),17),18)}。ユビキタスセンサを用いる手法は、ウェアラブルセンサを用いる手法に比べてユーザに装着の負荷を与えないが、数多くのセンサを環境に設置し、それらをメンテナンスするコストが非常に大きい。一方、家庭環境の一箇所もしくは少ない箇所にのみ家庭のインフラをモニタするセンサを設置し、行動認識を行う手法も存在する^{4),14)}。例えば、コンセントに設置したオシロスコープを用いて電源系統のノイズをモニタすることで、電化製品の利用を認識する手法などがある¹⁴⁾。多くの環境に設置したセンサを用いる手法では、環境内の日常物の利用をユビキタスセンサやインフラに設置したセンサで検知し、その情報を用いて高度な行動の認識を行なっている。これらの手法は、「ユーザが使っているモノは、ユーザが行っている行動に関連する」という考えに基づくものである。例えば、あるユーザが髭剃りとシェービングローションを使っているとき、そのユーザが髭剃りをしていると容易に認識できるだろう。

上述の通り、環境に設置したセンサを用いる手法は、モノの利用の情報を用いることで、ある程度高度な行動を認識できる。一方、ウェアラブルセンサを用いる多くの手法では、身体に装着した加速度センサから得られたデータを用いるため、歩行や走行などのある程度単純な行動しか認識することができない。しかし、環境に設置したセンサを用いる手法とは異なり、ユーザの屋外での行動も認識することが可能である。また、導入・管理のコストが

^{†1} NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories

環境に設置したセンサに比べて小さい。そこで、本稿では、導入・管理コストが少ないウェアラブルセンサを用いてモノの利用を検知することで、高度な行動の認識を目指す¹¹⁾。すなわち、ユーザの身体に装着したセンサのみを用いて、ユーザが使っているモノの認識を行う。これにより、少ない導入・管理コストで、ユーザが使っているモノの認識を、屋内外問わず行うことができる。特に、本稿では手に装着した磁気センサを用いて、手で使っている(持っている)携帯電話、デジタルカメラ、ヘアドライヤ、電動髭剃りなどの携帯型電化製品の利用を検知することを目指す。具体的には、電化製品から発せられる磁場を手に装着した磁気センサにより観測することで、ユーザが手で使っている電化製品を機械学習のアプローチを用いて推定する。現代社会では、われわれは数多くの電化製品に囲まれて暮らしており、それらの利用を検知することで、さまざまな高度な行動の認識が可能となるだろう。例えば、ユーザがデジタルカメラを使っていることが認識できれば、そのユーザが写真を撮っていることが高い確率で分かるだろう。このような行動の認識技術は、ライフログアプリケーションやコンテキストウェアシステムの基盤的技術の1つであるため、ユーザが利用している電化製品の利用を検知・認識する研究はこれまでに数多く行われている。しかし、電化製品ごとにセンサを設置する必要がある手法⁶⁾や、家庭のインフラに接続した電化製品の利用のみしか検知できない手法¹⁴⁾しかこれまでに存在しなかった。一方、本稿でわれわれが提案する手法は、電化製品内の磁石やコイルなどから発せられる磁場を用いるため、家庭のインフラに接続していない携帯型電化製品の利用を検知できる。また、提案手法は屋内外を問わず、利用している電化製品を認識出来る。デジタルカメラや携帯電話などに代表される携帯型電化製品は、屋外で使われることが多い。

本稿では、2章でセンサデータを用いた行動認識に関する関連研究を紹介したあと、3章で電化製品から発せられる磁場と磁気センサのメカニズムについて説明する。そして、4章でわれわれの提案するセンサデバイスの設計と実装について述べ、5章でセンサデバイスを用いて電化製品の利用を認識する手法の説明を行う。6章では、センサデバイスを用いて実際の3つの家庭環境でセンサデータの収集を行い、収集したデータを用いて提案認識手法の評価を行う。本稿で提案する手法のように、環境に設置したセンサを用いずに、携帯型電化製品の利用を検知する手法は、われわれの知る限り存在しない。また本稿では、ユーザの手のどの位置にどの程度の数の磁気センサを添付すればよいかを実験的に確かめる。これにより、できるだけ少ない数の磁気センサでの認識を目指す。

2. 関連研究

1章で述べたように、行動認識手法は大まかに環境設置のセンサか身体装着のセンサを用いるものに分けられる。環境設置のセンサを用いる多くの手法は、大量の小型スイッチセンサ、RFID タグ、加速度センサなどを環境内の日常物に添付している^{15),17),18)}。この手法はきめ細やかに日常生活を観測できるが、センサの導入・メンテナンスコストが大きい。家庭内のインフラに設置した少数のセンサを用いることで、少ないコストで家庭内の電気、水道、ガスなどの利用を検知する手法も存在する^{3),4),14)}。しかし、このような手法は、家庭のインフラに接続していない機器や日常物の利用を検知できない。一方、本稿で提案する手法は、家庭の電気系統に接続していない携帯型電化製品の利用を身体に装着したセンサを用いて観測する。本手法と家庭のインフラを観測する手法を併せて用いることで、インフラに接続している電化製品の利用とそれ以外の電化製品の利用の両方を観測できるだろう。

身体装着のセンサを用いた多くの手法が、身体のさまざまな部位に添付した加速度センサを用いている^{1),16)}。そのため、‘歩く’や‘走る’といったある程度単純な行動の認識しかできない。一方、マイクやカメラといったリッチなセンサを身体に装着することで、高度な行動の認識を行う手法も存在する^{2),8),10),12),13)}。しかし、リッチなセンサを用いた場合、プライバシーや電力消費量の増大の問題が発生する。本稿で用いる磁気センサは、加速度センサのように数値の系列を出力し、その電力消費量も少ない。

3. 磁場と磁気センサ

提案手法について説明する前に、電化製品から発せられる磁場と磁気センサのメカニズムについて簡単に説明する。

3.1 電化製品から発せられる磁場

電化製品内には、主に2つの磁場の発生源がある。1つ目は電化製品内の永久磁石である。永久磁石は、モータ、スピーカ、イヤホンなどの部品の一部として用いられることが多く、われわれの日常生活にもなじみ深い。磁石から発せられる磁場は、磁石からの距離に従って、大きく減衰する。減衰の特徴は、磁石の強さや形状に依存する。例えば、水平平面に置かれた直径5mm、厚さ3mm、残留磁化1.2 Tの円柱形の磁石の場合、垂直方向に5mmおよび10mmの位置の磁場はそれぞれ36.0 mTと7.1 mTである。2つ目の発生源は電化製品内を流れる電流である。製品内のコイル、IC、導線などの電流が流れる部品からは磁場が発生しており、この磁場も距離に応じて大きく減衰する。また、ICや導線などから発せられ

る磁場は、コイルや磁石からのものに比べてその強度はかなり小さく、地磁気 (0.03 - 0.04 mT) よりもかなり小さいことが多い。われわれは、磁気センサを身体に装着することを想定しており、そのようなセンサは、その向いている方向が装着者の向きや姿勢により変わるため、そのような環境下で地磁気より小さな磁気の変化を捉えることは難しいと考える。

3.2 磁気センサ

磁場の検知には、電流の観測、方角の観測、病気の診断、紙幣の検証など、さまざまな応用があるため、数多くの種類の磁気センサが開発されている⁷⁾。ここでは、広く使われているホール素子を用いた磁気センサについて紹介する。ホール素子は、電流の流れる導体に対して、電流に垂直に磁場をかけると現れる起電力を利用することで、磁場の検出を行う。ホール素子は、それを貫く磁束密度に比例した電圧を出力する。ホール素子を用いた磁気センサは、その構成のシンプルさゆえ、1 から 2mm 角の小型で安価なものも開発されている。

4. センサデバイスの設計

4.1 携帯型電化製品の利用

われわれは、携帯電話やカメラといった携帯型電化製品を手によって把持し、操作する。また上述したとおり、電化製品から発せられる磁場は、距離に応じて大きく減衰する。そこで、われわれは手に磁気センサを装着することで、電化製品から発せられる磁場を近い距離から観測する。特に、われわれは指の関節と関節の間に指輪型の磁気センサを搭載したセンサデバイスを装着することを想定する。デバイスを関節と関節の間に装着すれば、指を曲げる際の妨げとならないだろう。また、人が普段から身に着けることの多い指輪の形状とすることで、装着の負荷も低減できると考える。

われわれは、このようなセンサデバイスから得られた磁気センサデータを用いて、教師あり機械学習のアプローチにより、電化製品の利用の認識を行う。これは、「ユーザが何らかの携帯型電化製品を操作する際、その持ち方は操作のたびにほぼ同じだろう」というわれわれの考えを基にしている。カメラ、携帯電話、電動歯ブラシなどの電化製品は、操作のためのボタンなどを備えるため、ユーザがそれらを操作するときの持ち方は、その操作のたびにほぼ同じだろう。持ち方がほぼ同じであれば、操作のたびにセンサデバイスから得られるセンサデータ系列もほぼ同じであるため、教師あり機械学習を用いることで、それらの利用を検知できるだろう。

4.2 プロトタイプデバイスの設計と実装

以上のような考えを基に、主に指に注目したセンサデバイスの設計・実装を行う。ただし、



図 1 磁気センサ (左) とプロトタイプデバイス (右)。図のようにグローブ上のそれぞれのセンサに識別子を与えている。識別子の最初の文字が手の左右 (L または R) を表し、2 番目は手の部位、最後はシリアルナンバーを表す。例えば、右手の小指 (little finger) の 1 番目のセンサの識別子は R-L1 である。




図 2 携帯電話を R-II のセンサに近づけたあと、遠ざけたときに、そのセンサから得られたデータ系列。

どの指のどの部位に注目して磁場を観測すれば効果的であるかは明らかではない。また、どの程度の数のセンサを用いれば、高い精度での認識が可能かも明らかではない。そこで、われわれはまず、重要と考えられる手のいくつかの部位に磁気センサを搭載したセンサデバイスを実装し、そのデバイスを用いて認識に有用な部位を実験的に検証する。図 1 に、われわれが実装したグローブ型センサデバイスを示す。センサデバイスは、主に指の関節と関節の間に 10 個の磁気センサ (旭化成 HW105A ホール IC) を搭載しており、右手用と左手用のデバイスをそれぞれ製作した。図 1 に示すように、センサは十分に小さい。われわれは、3.1 章で述べたような地磁気や永久磁石が発する磁場の大きさの範囲を計測できるセンサを選んだ。このプロトタイプでは、それぞれのセンサがセンサボードを介してホスト PC の USB ポートに接続されている。センサボードは、それぞれのセンサから 330 Hz でセンサデータをサンプリングする。

4.3 センサデータの特徴

図 3 (a)-(f) は、デバイスの装着者が「写真を撮る」行動を異なる場所と日時に行ったときに、両手中指のセンサから得られたセンサデータである。具体的には、デジタルカメラを手に取り、その電源を付け、写真を撮り、電源を切り、カメラを手放すという一連の行動である。グラフの x 軸と y 軸は、時刻とセンサの出力電圧を表す (出力電圧はシフトしている。) 図 3 (a)-(d) から、異なる日時に得られたデータでも、カメラを把持している間のデータの値は類似していることが分かる。また、図 3 (e) と (f) は、送電塔と線路の近くで写真を撮ったときのセンサデータである。これらは強い磁場を発していると考えられるが、

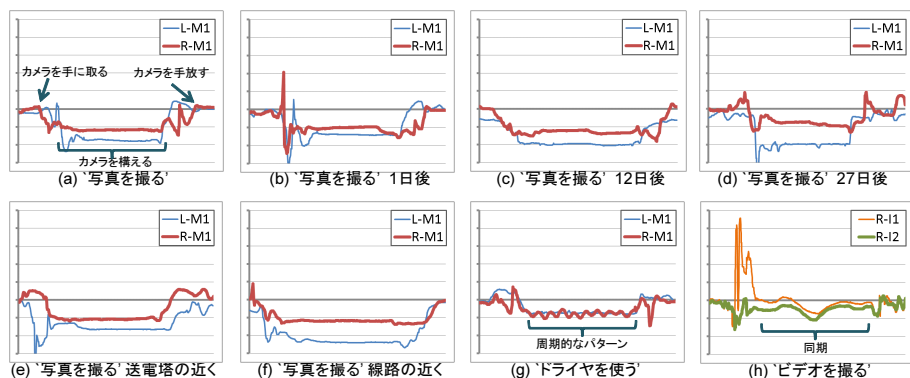


図3 プロトタイプデバイスから得られたセンサデータ系列。センサデータの正負は、センサを貫通する磁束の方向を示す。

上述のように磁場は距離に応じて大きく減衰するため、ある程度の距離にある磁気センサへの影響は小さい。一方、図3(g)は、装着者がヘッドライヤを使ったときのセンサデータ系列であり、それは写真を撮ったときのものとは大きく異なることが分かる。

5. 認識手法

図4に、上述したような特徴を持つセンサデータを用いて電化製品の利用を認識する手法の構成を示す。われわれは、出力電圧値を増幅したあと、ローパスフィルタを用いて高周波のノイズを除去する。図2に示すように、センサの出力電圧には高周波のノイズが含まれる。そして、ホストPCは33 Hzでノイズ除去後のセンサデータをサンプリングする。ホストPCはそれぞれの時間窓ごとにセンサデータから特徴抽出を行い、抽出された特徴ベクトルを適切な行動のクラス（電化製品の利用のクラス）に分類する。以降にそれぞれの処理について説明する。

5.1 特徴抽出

われわれは、それぞれのセンサデータのサンプルごとに特徴抽出を行う。ホストPCは、33 Hzでサンプリングをするため、1秒間に33の特徴ベクトルが作られ、分類手法への入力となる。われわれは、ノイズ除去を行った出力電圧に加えて、(i) エネルギー、(ii) 主要周波数、(iii) 異なるセンサごとの出力電圧の差を特徴として用いる。

エネルギーと主要周波数は、それぞれのセンサデータ系列ごとに求める。これらの特徴は、それぞれのデータサンプルを含む直前の64サンプル窓のFFT係数から計算する。こ




図4 認識手法の構成。

れは、図3(g)のように、センサデータに周期的な特徴をもつ行動が存在するためである。エネルギーは、センサデータの大きな変化を含む行動と、そうでない行動を分類するために用いる。エネルギーは、FFT成分ごとの振幅の二乗を合計し、さらにウィンドウサイズで除算することで正規化したものである。ただし、その合計からFFT成分の直流成分は除いている。主要周波数は、最大のFFT係数をもつ周波数に対応し、センサデータの周期が異なる行動同士を分類するために用いる。

また、同じ時刻にサンプリングされた異なる2つのセンサの出力電圧値の差も特徴として用いる。われわれは、同じ手に装着された2つのセンサのすべての組み合わせごとに差を計算し、それぞれを特徴として用いる。3.1章で説明したとおり、磁気センサは地磁気に影響を受ける。図3(h)は、デバイス装着者がデジタルカムコーダを用いているときのセンサデータを示しており、2つのセンサデータ系列が同期して変化していることが分かる。これは、装着者がその向きを変えたときに、地磁気により引き起こされたものである。異なる2つのセンサデータの差を求めることで、地磁気（方向の変化）によって引き起こされるデータの変化を打ち消すことができると考える。

以上のような特徴を計算し、結果の値を結合することで、特徴ベクトルを作成する。

5.2 分類手法

われわれは、教師あり機械学習のアプローチを用いて、抽出されたそれぞれの特徴ベクトルを、適切な行動のクラスに分類する。すなわち、ラベル付きトレーニングデータを用いて行動（電化製品の利用）を学習したあと、学習したモデルを用いてテストデータを認識する。ラベルとは、行動のクラスと行動の開始・終了時間の情報を含むものである。ここで、機械学習において用いられる分類手法は、識別モデルを用いるものと、生成モデルを用いるものに大まかに分けられる。クラス間の境界を学習する識別モデルは、生成モデルより分類問題に適している。一方で、生成モデルの方が欠損データの扱いに長けている。いくつかの最新の行動認識研究では、それらの長所を生かした識別・生成ハイブリッドモデルを用いた

表 1 実験の条件

家	家 A	家 B	家 C
部屋数	7	5	2
期間	8	4	7
セッション数	10	6	12
参加者の年齢	60	35	32
参加者の性別	男	男	男

表 2 実験で行われた行動

行動		行動	
A	携帯電話で話す	H	掃除機掛けをする
B	携帯電話を使う	I	TV を見る
C	スマートフォンを操作する	J	TV ゲームをする
D	音楽を聴く	K	ラジオを聴く
E	髭を剃る	L	懐中電灯を使う
F	ドライヤを使う	M	写真を撮る
G	歯を磨く	N	ビデオを撮る

行動認識が行われており、高い精度を達成している^{5),8),9),12)}。

以上の理由から、図 4 のように、識別・生成ハイブリッドモデルを用いている。分類手法は、識別型分類器と生成型分類器の 2 つのモジュールからなる。1 つ目のモジュールの入力は、特徴ベクトル系列である。1 つ目のモジュールは行動ごとに用意した識別型分類器（決定木）であり、特徴ベクトルが対応する行動のクラスに分類されるか、そうでないかを学習・認識する（2 値分類問題）。つまり、図 4 中の n は、学習する行動のクラスの種類の数に対応する。それぞれの 2 値分類器は、特徴ベクトルごとに、対応するクラスに分類される確率を出力する。すなわち、1 つ目のモジュールからは、 n 次元の確率のベクトルの系列が出力され、2 つ目のモジュールへの入力となる。2 つ目のモジュールは、行動ごとに用意した left-to-right HMM¹⁹⁾ から構成され、それぞれの HMM は、それぞれの確率のベクトルに対して、対応する行動のクラスに分類される尤度を出力する。ある時刻において、最も高い尤度を出力した HMM に対応するクラスを、その時刻に行われた行動のクラスとする。

6. 評価実験

本章では、実環境で得られたセンサデータを用いて、行動認識手法の精度を評価する。また、どの程度の数のセンサを用いればどの程度の認識精度を達成できるのか、どの部位のセンサが認識精度の向上に貢献しているのかについても評価する。

6.1 データセット

プロトタイプデバイスを両手に装着した 3 人の実験参加者が各々の家（A, B, C）でセンサデータの取得を行った。デバイスは参加者が背負ったバックパック内のラップトップ PC に接続されている。センサデータへのラベル付けのため、参加者の体の正面付近を撮影するように設置したヘッドマウントカメラを用いて行動の様子を撮影した。表 1 に実験条件を示す。

実験参加者の日常生活から得られるデータが最も自然なデータであり、そのようなデータを用いて実験を行うことが望ましい。しかし、そのためには参加者の日常生活を常にモニタ

リングしておく必要があるため、そのようなデータを十分な量だけ集めることは困難である。われわれは、センサデータを文献 1) で用いられている手法を用いて収集する。その手法では、参加者は与えられたワークシートに従って行動を行う。ワークシートにより、参加者ごとにランダムに並べられた行動を順に行うように指示する。また、ワークシートによる指示は、「電動髭剃りで髭を剃る」、「家をハンディ掃除機で掃除機がけする」など、あいまいであるため、参加者はある程度自由に行動を行うことができる。実験では、表 2 に示した行動（携帯型電化製品の利用）を一通りランダムな順に行ってもらったセッションを、表 1 に示した回数行ってもらった。

ここで、表 2 のいくつかの行動について詳細に説明する。行動 B では、参加者に文字入力や番号入力などの携帯電話の操作を行ってもらった。行動 C では、任意の Web ページをスマートフォン上で閲覧してもらった。行動 E では、電動髭剃りで髭を剃ってもらった。行動 G では、電動歯ブラシで歯を磨いてもらった。行動 H では、ハンディ掃除機で家の中を掃除してもらった。行動 I では、テレビのリモコンを操作してもらった（チャンネルや音量を変えるなど）行動 J では、ニンテンドー DS や Wii などのゲーム機を利用してもらった。行動 K では、携帯型ラジオでラジオ番組を聴いてもらった。行動 M では、デジタルカメラで写真を撮ってもらった。行動 N では、デジタルカムコーダでビデオを撮ってもらった。携帯電話やデジタルカメラなどの、さまざまな場所で用いられるものに関しては、家の内外のさまざまな場所で使ってもらった。また、参加者の家に実験で利用する電化製品がない場合は、新しく購入してもらった。

6.2 評価結果

それぞれの家庭環境で得られたセンサデータごとに、Leave-one-session-out 交差検定を用いて行動認識手法の評価を行った。つまり、1 つのセッションで得られたデータをテストデータとし、残りのセッションで得られたデータをトレーニングデータとする。評価指標には、それぞれの特徴ベクトルの認識結果から計算した適合率と再現率を用いた。

6.2.1 認識精度

表 3 左部は、20 のすべての磁気センサから得られたセンサデータを用いて認識を行ったときの精度である。身体に装着したセンサのみで高い精度を達成しており、それぞれの家庭で約 80% の平均精度を達成していた。家 A と C の精度が B のものより高かった理由は、トレーニングデータ量の差によるものと考えられる。家 A では、「写真を撮る」の適合率が低かった。これは、家 A の参加者が写真を撮るとき、その被写体に依ってカメラの構え方をわずかに変えていたためである。例えば、接写をするときや、遠くの風景を撮るときなど

表 3 それぞれの家庭における認識精度（適合率 / 再現率）．値はパーセント．表の左部は、20 の全てのセンサから得られたデータを使ったときの結果を、右部は認識の貢献順に上位 4 つのセンサのみから得られたデータを使ったときの結果を示す．

	全てのセンサ			上位 4 つのセンサのみ		
	家 A	家 B	家 C	家 A	家 B	家 C
A: 携帯電話で話す	95.1/82.2	25.2/80.2	27.2/89.9	89.6/88.8	58.5/43.1	43.7/75.0
B: 携帯電話を操作する	89.5/84.9	89.4/73.3	98.2/80.4	70.0/79.9	58.1/73.5	91.9/89.7
C: スマートフォンを使う	92.5/76.0	91.4/85.5	91.6/83.6	68.0/64.9	77.4/61.7	98.4/93.4
D: 音楽を聴く	87.2/71.0	63.4/65.5	73.0/89.5	75.1/72.8	59.6/37.2	81.3/89.5
E: 髭を剃る	78.8/78.8	99.9/100.0	93.9/68.8	84.9/84.9	86.4/71.8	81.1/67.1
F: ドライヤを使う	95.9/99.4	94.4/89.9	91.2/89.3	91.4/93.7	96.1/95.5	97.2/94.0
G: 歯を磨く	95.4/95.5	79.6/51.2	79.2/67.4	65.7/79.0	50.8/81.0	55.7/72.0
H: 掃除機掛けをする	90.0/83.3	99.4/66.0	98.0/85.4	82.8/79.6	26.6/58.5	93.6/86.2
I: TV を見る	79.4/78.9	84.3/73.8	89.3/69.4	76.8/74.1	72.3/69.5	95.2/83.5
J: TV ゲームをする	95.5/97.7	99.3/99.5	95.9/85.8	88.8/96.0	99.1/100.0	88.8/89.8
K: ラジオを聴く	89.0/73.6	92.9/81.2	69.8/70.1	59.3/41.5	74.9/78.9	72.7/73.2
L: 懐中電灯を使う	86.9/90.7	95.2/80.0	98.3/71.6	58.3/80.8	22.7/21.6	80.9/73.2
M: 写真を撮る	35.3/77.2	98.4/92.0	90.8/99.9	82.5/82.8	99.0/88.8	73.8/75.2
N: ビデオを撮る	91.4/78.7	53.3/28.7	99.3/92.2	96.7/82.2	40.6/29.0	98.0/80.9
平均	85.9/83.4	83.3/76.2	85.4/81.7	77.9/78.7	65.9/65.0	82.3/81.6

に応じて構え方が異なった．構え方の変化は微少だったものの、図 5 (a) と (b) に示すように、得られたセンサデータ系列は大きく異なった．図 5 (a) は、家 A で参加者が正面の風景を撮影したときに得られたセンサデータ系列である．図 5 (b) は、家 A で参加者が被写体（物体）に直接カメラを向けて接写したときのセンサデータ系列である．L-M1 のセンサから得られた系列が大きく異なっている．3.1 章で述べたように、磁場は距離に応じて大きく減衰するため、センサの位置が変われば電化製品内の部品から発せられる磁場の観測値も大きく変わってしまう．この現象と似た現象は、家 B と C の「携帯電話で話す」の行動にも見られた．以上のように、電化製品の持ち方のさまざまな変化が精度の低下の原因の 1 つとなっていた．この問題に対処するためには、さまざまな持ち方を数多く含んだ多様なトレーニングデータをあらかじめ用意する必要があるだろう．

磁気を発する部品の電化製品内における位置も精度の低下の原因の 1 つとなっていた．家 B において、「歯を磨く」と「ビデオを撮る」の行動の精度が低かった．これは、これらの行動の際にセンサから得られたセンサデータの値がとても小さかったためである．すなわち、電化製品内の磁気を発する部品と手に装着したセンサとの位置が遠かったためである．磁




図 5 実験で得られたセンサデータ系列の例．

気の変化がほとんど生じない行動を、われわれのアプローチで認識することは困難である．このような問題は、家 B の「歯を磨く」と「ビデオを撮る」、家 C の「TV を見る」の行動において見られた．家 B では電動歯ブラシから得られたセンサデータの値がとても小さかったにもかかわらず、「歯を磨く」の行動の認識精度はそれほど低くなかった．家 B の参加者が歯を磨いているとき、ブラシが前歯や奥歯、上の歯や下の歯に密着するように電動歯ブラシを動かしていた．すなわち、磨く場所に応じて手の姿勢を変えていた．4.3 章で述べたように、磁気センサは地磁気にある程度影響を受ける．手の姿勢が変わったとき、手に装着したセンサの姿勢も変わるため、それらのセンサから得られるセンサデータの値も変化する．図 5 (c) は、家 B の参加者が歯を磨いているときに得られたセンサデータ系列である．図から、R-I1 のセンサデータが唐突に変化していることが分かる．この変化は、手の姿勢の変化により引き起こされたと考えられる．認識手法が、このような変化を「歯を磨く」の行動の特徴として学習したため、ある程度の精度で「歯を磨く」の行動を認識できたと考えられる．以上のように、行動に特徴的な手の動きが含まれていれば、電化製品から大きな磁場を観測できない行動であっても、ある程度の精度で認識できることが分かった．

全てのセンサを用いたときの評価のさらなる詳細は、文献 11) を参照して欲しい．

6.2.2 少数のセンサでの認識

上記の評価では、20 の全てのセンサを用いることで高い認識精度を達成していたが、数多くのセンサを日常的に装着し続けることは難しい．ここでは、少ない数での高精度な認識を実現するため、どの位置に装着したセンサがどの程度認識に貢献しているかを検証する．具体的には、特徴ベクトル内のどの特徴の値が、特徴ベクトルの分類に貢献しているかを求めることで検証する．例えば、L-M2 のセンサから抽出した特徴の値が多く of 行動の認識に貢献していたとき、L-M2 のセンサは認識に貢献していると言えるだろう．以上のように、分類問題に貢献している特徴を求めることを、特徴選択と言う．


いくつかの先行研究において、情報利得の概念を用いて特徴選択を行なっている。特徴の情報利得が大きいほど、その特徴の値を用いてインスタンスを分類したときの精度が高い。われわれの場合、インスタンスは特徴ベクトルに対応する。詳細は、文献 20) を参照して欲しい。われわれは、それぞれのセンサの分類の貢献度（情報利得）を用いて、20 のセンサのランキングを作成する。その手順は以下の通りである。(1) それぞれの特徴（特徴 f_i とする）ごとに、ある行動クラス (C_j) とそれ以外のクラスを分類する際の情報利得 ($gain(f_i, C_j)$) をトレーニングデータを用いて計算する。この処理を全ての行動クラスごとに行う。(2) それぞれの特徴（特徴 f_i とする）ごとに、全てのクラスの情報利得の合計を計算する。この合計値を、その特徴の貢献度とする。貢献度は、 $score_f(i) = \sum_j gain(f_i, C_j)$ のように表される。(3) センサ k の貢献度は、そのセンサに関連する特徴の貢献度の合計とし、 $score_s(k) = \sum_{f_i \in F(k)} score_f(i)$ のように表される。ここで、 $F(k)$ は、センサ k のデータから計算される特徴のセットである。(4) 計算した $score_s(k)$ を用いて、20 のセンサのランキングを作成する。

図 6 (a) の表は、それぞれの家庭環境におけるセンサのランキングの上位 8 センサを示している。表中の「all」の列は、全ての 20 のセンサの上位 8 センサのランキングである。全ての 3 つの家庭環境のランキングにおいて、右手のセンサの順位が高いことが分かる。これは、3 人の参加者が右利きであり、多くの行動において右手で電化製品を使うことが多かったためである。特に、右手の中指の順位が高かった。これは、中指が手の中央に近い位置にあるためだろう。そのような位置にあるセンサの方が、小指などの外れた位置にあるセンサに比べて、手に把持された電化製品との位置が近いことが多いと考えられる。一方、表中の「ring」の列は、一般的な指輪を装着する位置にある 10 のセンサの上位 8 センサのランキングである。10 のセンサとは、(L|R)-T1, (L|R)-I2, (L|R)-M2, (L|R)-R2, (L|R)-L2 のセンサに相当する。すなわち、一般的な指輪の位置に装着されるセンサデバイスに、磁気センサが搭載されていることを想定しているランキングである。このランキングでも、右手のセンサの順位が同様に高かった。


図 6 (b), (c), (d) は、表 (a) のランキングの上位の順に認識に用いるセンサ数を増やしたときの認識結果の F 値 (F-measure) の変化を示す。例えば、家 A においてセンサ数が 2 のとき、「F-measure (all)」の線の y 軸の値は、家 A における上位 2 センサである R-M1 と R-M2 のセンサから得られたデータのみを用いて認識を行ったときの認識精度 (F 値) に相当する。これらのグラフを用いて、必要なセンサ数について検証する。これらのグラフから、7 つほどのセンサから得られたデータを用いれば、20 の全てのセンサを用いたときと

	家 A		家 B		家 C	
	all	ring	all	ring	all	ring
1st	R-M1	R-M2	R-T1	R-T1	R-I1	R-I2
2nd	R-M2	R-R2	R-M1	R-M2	R-M1	R-M2
3rd	R-R1	R-I2	R-M2	R-I2	R-I2	R-T1
4th	R-R2	R-T1	R-I2	L-R2	R-M2	R-L2
5th	R-I2	L-I2	R-P1	L-L2	R-R1	L-T1
6th	R-T1	L-M2	L-P1	L-I2	R-P1	L-I2
7th	L-I1	L-T1	R-I1	L-M2	R-L1	L-R2
8th	L-M1	R-L2	L-R2	R-R2	R-T1	L-L2


(a) センサのランキング



(c) 家 B



(b) 家 A



(d) 家 C

図 6 (a): それぞれの家庭での磁気センサのランキング。全ての 20 のセンサの上位 8 センサのランキングと、指輪の位置として一般的な位置にある 10 のセンサの上位 8 センサのランキングを示す。(b), (c), (d): ランキングの上位の順に認識に用いるセンサ数を増やしたときの認識結果の F 値 ($F\text{-measure} = \frac{2 \cdot \text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$) の変化。

同等の認識精度が達成できていることが分かる。家 A と C では、上位 3 つのセンサだけでも 75% 以上の高い精度を達成している。表 3 の右部は、上位 4 つのセンサのみから得られたデータを用いたときの精度を示している。4 つのセンサしか用いていないにも関わらず、平均の精度は全てのセンサを用いたときと比べて、5 から 10% 程度しか低下していない。また、図 6 (b), (c), (d) の「F-measure (all)」に示すように、一般的な指輪の位置のみに限定したとき、それらの精度は幾分低下している。しかし、家 A や C では、4 や 5 つのセンサだけでも 75% 以上の精度を達成している。家 B の精度の変化が安定していないのは、トレーニングデータ量が少なかったためと考える。

上記の結果のように、少ない数の磁気センサを用いて携帯型電化製品の利用を高い精度で

認識できた。厳密に言うと、図 6 (a) のランキングに示すように、それぞれの家庭環境において認識精度の向上に大きく貢献しているセンサの位置は異なった。しかし、いずれの家庭環境においても、いくつかの数のセンサを利き手の中央の位置に近い指に装着するだけで、ある程度の精度の認識が可能であると考え（実際に、R-M1, R-M2, R-I1, R-I2 の 4 つのセンサを用いることで、家 A, B, C において 76.8, 67.6, 82.7% の F 値を達成していた。）特に、中指に装着したセンサの認識における貢献度は高かった。

7. おわりに

本稿では、手に装着した磁気センサを用いて携帯型電化製品の利用を認識する新しい手法を提案した。現代社会ではわれわれは数多くの電化製品に囲まれて暮らしており、それらの利用を検知することでさまざまな行動の認識が可能であるため、電化製品の利用の検知・認識に関する数多くの研究が行われている。本稿で提案した手法では、電化製品に直接添付したセンサなどを用いることなく、家庭のインフラに接続していない電化製品の利用を、ウェアラブルセンサを用いて認識する。本稿では、実家庭環境において提案手法の評価を行い、高い精度を達成した。また、手に装着した数の少ないセンサのみでも、高い精度で認識ができることを確認した。今後は、携帯型電化製品の利用だけでなく、「歩く」や「走る」などの手の特徴的な動きを伴う単純な行動の認識も手に装着した磁気センサを用いて行う予定である。実験において確かめられたように、磁気センサは地磁気に影響を受けるため、手に装着した磁気センサを用いて特徴的な手の動きを捉えられると考える。これにより、手に装着した磁気センサを用いるだけで、携帯型電化製品の利用と手の特徴的な動きを伴う単純な行動の両方を認識できるようになるだろう。

参考文献

- 1) L.Bao and S.Intille. Activity recognition from user-annotated acceleration data. In *Pervasive 2004*, pages 1–17, 2004.
- 2) M.Blum, A.Pentland, and G.Troster. Insense: Interest-based life logging. *IEEE Multimedia*, 13(4):40–48, 2006.
- 3) G.Cohn, S.Gupta, J.Froehlich, E.Larson, and S.Patel. GasSense: Appliance-level, single-point sensing of gas activity in the home. In *Pervasive 2010*, pages 265–282, 2010.
- 4) J.Froehlich, E.Larson, T.Campbell, C.Haggerty, J.Fogarty, and S.Patel. Hydrosense: Infrastructure-mediated single-point sensing of whole-home water activity. In *UbiComp 2009*, pages 235–244, 2009.

- 5) T.Huynh and B.Schiele. Towards less supervision in activity recognition from wearable sensors. In *Int'l Symp. on Wearable Computers*, pages 3–10, 2006.
- 6) Y.Kim, T.Schmid, Z.Charbiwala, and M.Srivastava. ViridiScope: design and implementation of a fine grained power monitoring system for homes. In *UbiComp 2009*, pages 245–254, 2009.
- 7) J.Lenz. A review of magnetic sensors. *Proceedings of the IEEE*, 78(6):973–989, 1990.
- 8) J.Lester, T.Choudhury, and G.Borriello. A practical approach to recognizing physical activities. In *Pervasive 2006*, pages 1–16, 2006.
- 9) J.Lester, T.Choudhury, N.Kern, G.Borriello, and B.Hannaford. A hybrid discriminative/generative approach for modeling human activities. In *IJCAI 2005*, pages 766–772, 2005.
- 10) P.Lukowicz, J.Ward, H.Junker, M.Stager, G.Troster, A.Atrash, and T.Starner. Recognizing workshop activity using body worn microphones and accelerometers. In *Pervasive 2004*, pages 18–32, 2004.
- 11) T.Maekawa, Y.Kishino, Y.Sakurai, and T.Suyama. Recognizing the use of portable electrical devices with hand-worn magnetic sensors. In *Pervasive 2011*, pages 276–293, 2011.
- 12) T.Maekawa, Y.Yanagisawa, Y.Kishino, K.Ishiguro, K.Kamei, Y.Sakurai, and T.Okadome. Object-based activity recognition with heterogeneous sensors on wrist. In *Pervasive 2010*, pages 246–264, 2010.
- 13) W.Mayol and D.Murray. Wearable hand activity recognition for event summarization. In *Int'l Symp. on Wearable Computers*, pages 122–129, 2005.
- 14) S.Patel, T.Robertson, J.Kientz, M.Reynolds, and G.Abowd. At the flick of a switch: Detecting and classifying unique electrical events on the residential power line. In *UbiComp 2007*, pages 271–288, 2007.
- 15) M.Philipose, K.Fishkin, and M.Perkowitz. Inferring activities from interactions with objects. *IEEE Pervasive Computing*, 3(4):50–57, 2004.
- 16) N.Ravi, N.Dandekar, P.Mysore, and M.Littman. Activity recognition from accelerometer data. In *IAAI 2005*, volume 20, pages 1541–1546, 2005.
- 17) E.Tapia, S.Intille, and K.Larson. Activity recognition in the home using simple and ubiquitous sensors. In *Pervasive 2004*, pages 158–175, 2004.
- 18) T.van Kasteren, A.Noulas, G.Englebienne, and B.Krose. Accurate activity recognition in a home setting. In *UbiComp 2008*, pages 1–9, 2008.
- 19) L.R. Welch. Hidden markov models and the baum-welch algorithm. *IEEE Information Theory Society Newsletter*, 53(4), 2003.
- 20) I.Witten and E.Frank. *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2004.