情報処理学会論文誌 Vol.56 No.1 239–249 (Jan. 2015)

手に装着したコイルを用いた携帯型電化製品の利用の認識

前川 卓也[1,a)] 岸野 泰恵[2,b)] 柳沢 豊[2,c)] 櫻井 保志[3,d)]

受付日 2014年4月24日, 採録日 2014年10月8日

概要：本論文では，デジタルカメラや，携帯電話，電動歯ブラシ，ヘアドライヤといった携帯型電化製品の利用を認識するための，指輪形センサデバイスのプロトタイプの設計と実装を行う．提案デバイスはコイルを含み，電化製品から発せられる磁場の変化をとらえることができる．近年，ユビキタスコンピューティング研究の分野において，家庭内の電化製品の利用のセンシングに関する研究が数多く行われている．センシングした電化製品の利用情報は，家庭内のユーザの行動理解や認識に用いられる．本研究で提案するアプローチでは，家庭内の電気系統に接続していない電化製品の利用を，電化製品にセンサを添付することなくセンシングすることができる．また，実際の家庭環境で得られたセンサデータを用いて，提案デバイスを用いた電化製品の認識の評価を行った．実験により，モータを内蔵する電化製品の認識精度が特に高いことや，多くの電化製品において把持する方法は人によらず共通しているため，他のユーザ同士で認識用訓練データが共有可能であることなどが明らかとなった．

キーワード：ウェアラブルセンサ，電化製品，行動センシング

Recognizing the Use of Portable Electrical Appliances Using Hand-worn Coil

Takuya Maekawa[1,a)] Yasue Kishino[2,b)] Yutaka Yanagisawa[2,c)] Yasushi Sakurai[3,d)]

Received: April 24, 2014, Accepted: October 8, 2014

Abstract: This paper describes the development of a new finger-ring shaped sensor device with a coil of wire for recognizing the use of handheld electrical devices such as digital cameras, cellphones, electric toothbrushes, and hair dryers by sensing time-varying magnetic fields emitted by the devices. Recently, sensing the usage of home electrical devices has emerged as a promising area for activity recognition studies because we can estimate high-level daily activities by recognizing the use of electrical devices that exist ubiquitously in our daily lives. A feature of our approach is that we can recognize the use of electrical devices that are not connected to the home infrastructure without the need to equip them with sensors. We evaluated the performance of our approach by using sensor data obtained from real houses. The evaluation revealed that our approach can successfully recognize the use of appliances with motors. Also, because the ways of holding many appliances do not depend on people, we could share training data for recognition among users.

Keywords: wearable sensors, electrical devices, activity sensing

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ア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

[1] 大阪大学大学院情報科学研究科
Osaka University, Suita, Osaka 565–0871, Japan
[2] NTT コミュニケーション科学基礎研究所
NTT Communication Science Laboratories, Souraku, Kyoto 619–0237, Japan
[3] 熊本大学自然科学研究科
Kumamoto University, Kumamoto 860–8555, Japan
[a)] maekawa@ist.osaka-u.ac.jp
[b)] kishino.yasue@lab.ntt.co.jp
[c)] kani@ieee.org
[d)] yasushi.sakurai@acm.org

© 2015 Information Processing Society of Japan

取得したセンサデータを用いて行動の認識を行う [1], [13]. 環境に設置したセンサによる手法では，多数の 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].

一方，近年のユビキタスコンピューティングの研究分野において，家庭の電化製品の利用の観測に関する研究が多く行われている．我々は数多くの電化製品に囲まれて暮らしており，何らかの行動をする際にそれらを利用することが多い．そのため，観測された電化製品の利用情報はユーザの行動推定に役立つ．たとえば，ユーザがヘアドライヤを使っていることが認識できれば，そのユーザが髪を整えていることが分かるだろう．これまでに，電化製品の利用の検知・認識には，環境に設置したセンサやウェアラブルセンサが用いられてきた．たとえば，それぞれの電化製品に添付したユビキタスセンサを用いて，電化製品の利用を検知する研究などがある [6], [17] が，大量のセンサを必要とするため導入やメンテナンスのコストが大きい．一方，少数のセンサのみで電化製品の利用を検知する研究も行われている．たとえば，文献 [3] で提案されている手法では，電力計の総電力負荷を単一のセンサで観測し，観測したセンサデータから統計的信号処理手法を用いて電化製品ごとの電力消費（利用）を推定している．

上記のような手法は，コンセントを介して家庭内の電気系統に接続された電化製品の利用を認識するものである．一方，本研究ではウェラブルセンサを用いて，デジタルカメラ，携帯電話，電動シェーバ，携帯型ゲーム機，携帯型音楽プレイヤなどの携帯型電化製品の利用を認識することを目指す．文献 [10] で提案されたシステムでも，本研究と同様に携帯型電化製品の利用の認識に着目しており，手に装着したホール素子を用いて電化製品内の磁石やモータから発せられる比較的大きな磁場をとらえている．しかし，80%以上の高い認識精度を達成するためには，手の複数の部位にホール素子を装着する必要があった（詳細は 2 章を参照）．一方本研究では，手に装着した単一のコイルのみを用いて，電化製品内の電気回路，モータ，増幅回路，導線などから発せられる時間的に変化する磁場を観測する．そして，得られたセンサデータの周波数解析を行ったあと，機械学習のアプローチを用いて電化製品の利用を認識する．

本研究では，手に装着した単一のセンサのみで携帯型電化製品の利用の認識を行う．ウェアラブルセンサを用いたアプローチは，日常生活においてユーザに装着の負担を強いるため，できるだけ少ない数のセンサのみでセンシングすることが重要である．また，提案手法はウェアラブルセンサを用いるため，家庭内の電気系統に接続していない電化製品の利用も屋内・屋外問わず認識できる．さらに，提案手法は環境に設置されたセンサ（たとえば電化製品に直接添付されたセンサなど）を必要としない．

以降では，まず電化製品の利用の認識・検知に関する関連研究を紹介したあと，センサデバイスのプロトタイプの実装について述べる．その後，センサデバイスから得られたデータを用いて電化製品の利用を認識する手法について説明する．そして，実際の 3 つの家庭から得られたセンサデータを用いて提案手法の評価を行う．筆者らの知る限り，手に装着した単一のコイルのみを用いて電化製品の利用を認識する研究はこれまでに行われていない．

2. 関連研究

電化製品の利用の認識には環境に設置したセンサやウェアラブルセンサが用いられる．前者のアプローチとしては，電化製品ごとに添付されたユビキタスセンサが用いられることが多い．文献 [6] で提案されたシステムでは，それぞれの電化製品に添付された照度センサや磁気センサを用いてそれらの利用や消費電力を観測している．文献 [17] では，日常物（電化製品を含む）の状態変化をとらえる無線センサノードを用いて行動認識を行っている．このようなユビキタスセンサを用いることで，きめ細やかな観測を行うことができるが，センサの設置やメンテナンスに要するコストは膨大である．一方，少数のセンサを用いて，家庭内の電化製品の利用を検知する研究も行われている．たとえば，文献 [3] で提案されているシステムでは，家庭の電力計の電流および電圧信号を観測するセンサを用いている．システムでは，センサから得られたセンサデータのみを用いて，統計的な信号処理技術により家庭内の電化製品ごとの利用の検知を試みている．文献 [2], [14] で提案されているシステムでは，家庭内の電気系統上のノイズを観測し，ノイズの周波数的な特徴を用いて電気系統にコンセント経由で接続している電化製品ごとの利用を教師あり機械学習のアプローチにより認識している．また，電源タップ型のセンサノードを用いた，電化製品の利用の認識に関する研究も行われている [5], [8]．電源タップ型のセンサノードは，通常のタップと同様に，それに接続した電化製品に電力を供給するだけでなく，その電化製品に流入する電流値を観測することができる．文献 [11] では，乾電池で稼働する携帯型電化製品の利用の認識を，乾電池型のセンサノードを用いて行っている．乾電池型センサノードは，通常の電池と同様に挿入された電化製品に電力を供給するだけでなく，その内部を流れる電流を観測できる．

一方，ウェアラブルセンサを用いて電化製品の利用を検知する研究も行われている．文献 [10] で実現されているシステムでは，手に装着したホール素子を用いてユーザが手で使っている電化製品から発せられる磁場を観測することにより，ユーザがどの電化製品を使っているかを認識している．ホール素子は，自身を貫通する磁束密度に比例した電圧を出力する．ホール素子は地磁気に影響を受けるため，センサを装着するユーザの方向に応じてセンサデータの値が変化してしまう．そのため，文献 [10] のシステムで

© 2015 Information Processing Society of Japan

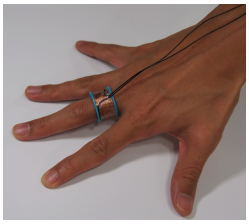


図 1 プロトタイプの指輪型センサデバイス
Fig. 1 Our prototype finger-ring shaped sensor device.

は，同じ手に装着した複数のホール素子から得られたセンサデータを用いて地磁気の影響を相殺している．しかし，日常生活における複数のセンサの装着は，ユーザに与える負担が大きい．また，文献 [10] のシステムでは，永久磁石やモータなどの地磁気に比べて大きな磁場を発する部品に着目していた．一方本研究では，電気回路，モータ，導線などから得られる時間的に変化する磁場に着目しており，変化の特徴的な周波数を用いることで地磁気の変化に影響を受けない電化製品の利用の認識を目指す．ここで，文献 [10] のシステムと本論文で提案するシステムは，互いに競合する技術ではなく，補完的な技術であると考える．懐中電灯やテレビリモコンなどの単純な電化製品の多くは，静的な磁場しか発しないため，文献 [10] のシステムでしか認識できないだろう．また，家庭内の電気系統に接続した電化製品の利用を認識する手法と本手法をあわせて用いることで，固定の電化製品であっても携帯型の電化製品であっても屋内・屋外を問わず利用を認識できると考えられる．

上記のような電化製品の利用を推定する研究の多くは，80%以上の認識精度を達成していた．これまでの電化製品利用認識研究では，ライフログや行動認識手法への入力を想定していたが，本研究でも同様の応用を想定するため，同程度の認識精度を達成する必要があると考える．また上記の用途では，センサデバイスの日常生活での常時装着が必要となる．そのような装着の負荷を抑えるため，装着するセンサデバイスの数は少ないほうが望ましい．本研究では 1 つのセンサデバイスのみでの認識を実現する．

3. プロトタイプセンサデバイス

3.1 設計と実装

1 章および 2 章で述べたように，本研究では携帯型電化製品から発せられる時間的に変化する磁場をとらえるセンサデバイスを実現する．そのために，本研究ではコイルを用いる．コイル内を貫通する磁束が変化すると，ファラデーの電磁誘導の法則（$V = -N\frac{d\Phi}{dt}$）に従って起電力が生じる．このとき，V は起電力，N はコイルの巻き数，$\frac{d\Phi}{dt}$ は磁束の変化を表す．このようにコイルを用いることにより，時間的に変化する磁場を電圧に変換し，センサデータとして観測することができる．ここで，ユーザが身体に

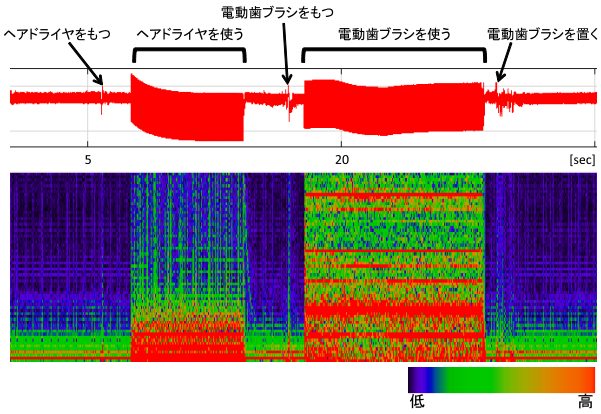


図 2 ヘアドライヤと電動歯ブラシを用いたときの，右手の中指に装着したセンサデバイスから得られたセンサデータ
Fig. 2 Example sensor data obtained from our finger-ring device worn on the right middle finger when the wearer used a hair dryer and an electric toothbrush.

センサ（コイル）を装着するとき，ユーザの向いている方向が変化すればコイルを観測する磁束（地磁気）も変化する．しかし，センサは磁束の変化量のみをとらえるため，方向の変化による影響はある程度小さいと考える．3.2 節において，プロトタイプデバイスから実際に得られたセンサデータとあわせて説明する．ここで，磁場はその発生源からの距離に応じて大きく減衰するため，携帯型電化製品を把持するユーザの手にセンサを装着する必要がある．透過的な行動センシングを実現するためには，指輪や腕輪，腕時計などのユーザが日常的に身につけるものにセンサを埋め込むべきだろう．コイルをセンサとして用いるアプローチは，指輪型センサデバイスの製作に適していると考える．これは，指輪に導線を巻き付けるだけで，容易にデバイスを製作できるためである．**図 1** に，プラスチックの輪に導線を巻き付けることで製作したプロトタイプの指輪型デバイスを示す．コイルの巻き数は約 2,000 である．デバイスはプロトタイプであるため，センサボードを介して USB ケーブルでホスト PC に接続している．コイルはセンサボード上の抵抗に接続しており，電磁誘導によりコイル（抵抗）に流れる電流を AC 電流センサを用いて計測する．その後，電流センサの出力（電圧値）をセンサボード上のオペアンプにより増幅する．増幅されたセンサデータ（電圧値）をセンサボード上のマイコンにより約 2,000 Hz でサンプリングしたあとホスト PC に送信する．このサンプリングレートはマイコンおよび PC によりサンプリング可能な最大のものである．

3.2 センサデータ

プロトタイプデバイスから得られたセンサデータの例を示す．**図 2** 上部は，ユーザの右手の中指に装着したセンサデバイスから得られた時系列センサデータの例である．X 軸は時刻を，Y 軸は磁気センサデータの値を表す．図 2

© 2015 Information Processing Society of Japan

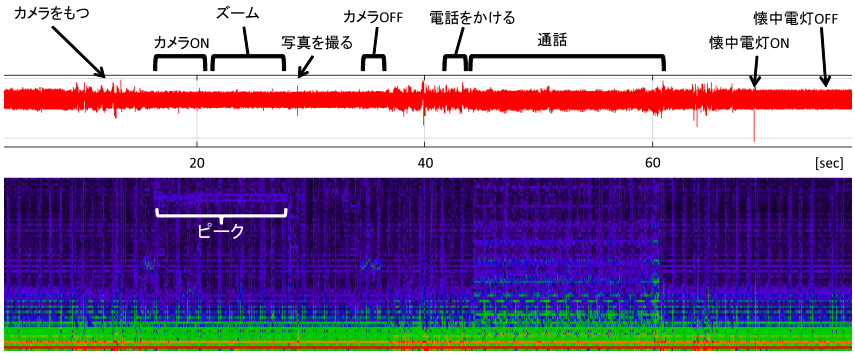


図 3 デジタルカメラ，携帯電話，および懐中電灯を用いたときの，右手の中指に装着したセンサデバイスから得られたセンサデータ

Fig. 3 Example sensor data obtained from our finger-ring device on the right middle finger when the wearer used a digital camera, a cellphone, and a flashlight.

下部は，時系列センサデータの周波数スペクトログラムを示す．スペクトログラムに示すように，ヘアドライヤと電動歯ブラシに関するピーク周波数はそれぞれ異なる．ここで，スペクトログラムには定常的にノイズが見られる．これは，センサボード上の増幅回路の影響と考えられる．また，センサデバイスは人の指に装着されるため，人体からの影響もある程度受けるだろう．

図 3 は，デジタルカメラ，携帯電話，および懐中電灯を用いたときのセンサデータと周波数スペクトログラムを示す．図のように，カメラレンズのモータが稼動しているときに特徴的なピークが見られる．（図 3 の「カメラ ON」と「ズーム」に対応）しかし，モータが稼動しているとき以外は，カメラの電源が ON の状態でも特徴的なピークは見られなかった．また，ユーザが携帯電話をかけている（ダイヤルしている）ときは特徴的なピークは見られなかったが，通話しているときは特徴的なピークが見られた．これは，電話の通信モジュールによるものと考えられる．懐中電灯を点灯したときは，過渡的なノイズが見られるが，点灯中は特徴的なピークは見られなかった．懐中電灯のような単純な電化製品の利用を提案デバイスで検出するのは難しいと考える．

ここで，センサデバイスに影響を与える外的要因について検証する．提案デバイスは，ユーザの近くにある強い磁場発生源に影響を受ける．**図 4** は，ユーザが携帯電話を右手で使いながら，左手で IH ヒータ上の鍋をかき混ぜているときに，ユーザの右手の中指に装着したデバイスから得られたセンサデータ（スペクトログラム）である．ユーザが携帯電話を体の正面の位置に持ち，電話をかけている（ダイヤルしている）ときは，デバイスが IH ヒータの近くにある（約 10〜20 cm）ため，その影響を受けている．一方，ユーザが携帯電話を耳に当て，通話しているときは，デバイスが IH ヒータから離れている（約 40〜50 cm）ため，その影響を受けていない．通話中のセンサデータは，図 3 のものとよく似ているといえる．**図 5** は，大型液晶

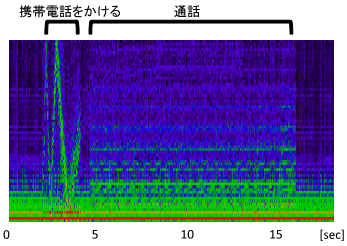


図 4 IH ヒータの近くで携帯電話を使ったときの周波数スペクトログラム

Fig. 4 Example spectrogram obtained in front of an induction heater.

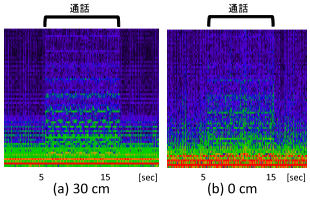


図 5 液晶テレビから 0 cm と 30 cm の距離で携帯電話を使ったときの周波数スペクトログラム

Fig. 5 Example spectrograms obtained when the wearer used a cellphone 30 and 0 cm from an LCD TV.

テレビの近くで携帯電話を使ったときのセンサデータである．テレビに接触して携帯電話を使ったとき（0 cm），全周波数帯域にノイズが乗っていることが分かる．一方，テレビからある程度離せば（30 cm），その影響はなくなっている．上記の例のように，提案デバイスは，強い磁場発生源に極端に近づかない限りは，その影響を受けない．これは，磁場が距離に応じて大きく減衰するためである．

図 6 (a) と (b) は，同じ場所で 2 人の異なるユーザから得られたセンサデータである．同じ場所で得られたにもかかわらず，図 6 内の矩形で示すように，周波数の特徴が多少異なる．図 6 (a) と (c) は，異なる場所で同じユーザから得られたセンサデータである．やはり，周波数の特徴は多少異なっている．上記のデータから，環境や人体（指）か

© 2015 Information Processing Society of Japan

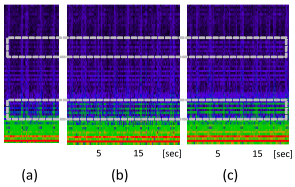


図 6 2 人の異なるユーザから異なる場所で得られたセンサデータ
Fig. 6 Example spectrograms obtained from different two wearers at different two places.

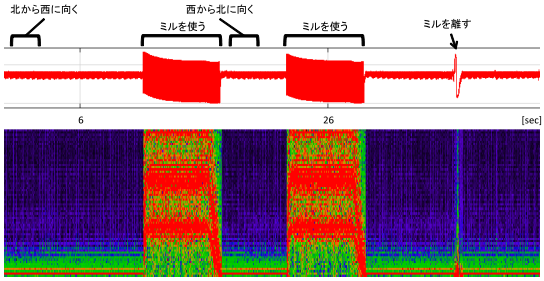


図 7 異なる方向を向いて電動ミルを使ったときのセンサデータ
Fig. 7 Example sensor data obtained when a wearer used a mill facing in different directions.

らの磁気ノイズにより提案デバイスはわずかに影響を受けていると考えられる．これらのノイズは，定常的に観測されるセンサデータに影響を与える．

3.1 節で述べたように，ユーザの向いている方向が変化すれば，ユーザの装着するセンサ（コイル）を貫く磁束も変化する．**図 7** は，ユーザが電動ミルを西および北を向いて使ったときに提案デバイスから得られたセンサデータと周波数スペクトログラムである．異なる方向を向いていても，得られるセンサデータには変化がないように見える．これは，提案デバイスが静的な磁場ではなく，時間的に変化する磁場のみをとらえるためである．ユーザが西や北を向いていても，センサを貫通する地磁気の磁束は一定であるため，センサデータに影響を及ぼさない．また，ユーザが向いている方向を変えたときも，センサデータには変化がないように見える．人が向きを変えるとき，センサを貫通する地磁気の磁束の時間的変化の大きさはそれ程大きくないため，センサデータに大きな変化を及ぼさなかったと考えられる．

4. 認識手法

センサデバイスから得られたセンサデータを用いて，ユーザが使っている電化製品を識別する．まず，センサデータから特徴抽出を行ったあと，隠れマルコフモデル（HMM）を用いて抽出された特徴ベクトルの認識を行う．以下で手法の詳細を説明する．

4.1 特徴抽出

時系列のセンサデータを扱うため，10 ミリ秒ずらしのスライディング時間窓ごとに特徴ベクトルを求める．128 サンプル窓ごとに求めた FFT 成分を基に特徴抽出を行う．3.2 節で述べたとおり，電化製品から発せられる磁場の周期的な変化は特徴的である．そこで，窓ごとに求めた FFT 成分を特徴として用いる．それに加えて，窓ごとに求めた分散とエネルギも特徴として用いる．エネルギは，FFT 成分ごとの振幅の二乗を合計し，さらにウイ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 の直流成分は除いている．以上のように，合計 66（64+1+1）次元の特徴ベクトルが時間窓ごとに計算される．

4.2 電化製品の識別

上記の手順により，特徴ベクトルの系列が得られる．教師あり学習のアプローチを用いて，系列内のそれぞれの特徴ベクトルを適切なクラス（電化製品）に分類する．すなわち，それぞれのクラスごとに用意したラベルありのトレーニングデータ（特徴ベクトル系列）を用いて，モデルを学習しておく．そして，学習したモデルを用いてテストデータの認識を行う．ここでラベルありデータには，クラス（電化製品）の識別子とその利用の開始・終了時刻の情報がアノテーションとして付与されている．それぞれの電化製品ごとに，left-to-right HMM を用いてモデルを学習する．HMM の観測変数は特徴ベクトルに対応し，その状態ごとの出力分布は混合ガウス分布でモデル化する．実装では，4 状態の HMM を用い，それぞれの混合ガウス分布の混合数は 4 とした．HMM のパラメタ推定には Baum-Welch アルゴリズム [16] を用いる．学習した HMM を用いてテストデータ（特徴ベクトル系列）を認識するときは，Viterbi アルゴリズムを用いて HMM 内および HMM 間の最も尤度の高い状態遷移系列を推定する [16]．推定された状態遷移系列から，時刻 t の特徴ベクトルがどの HMM（電化製品）に分類されたかが得られる．

4.3 不特定ユーザモデルの適応

あるエンドユーザによる電化製品の利用を認識するとき，そのユーザ自身でラベルありトレーニングデータを収集し，そのデータから学習したモデル（ユーザ依存モデル）を用いることは，ユーザに大きな負担を強いる．そのため 5 章では，あるエンドユーザの電化製品の利用（テストデータ）を，他のユーザのラベルありトレーニングデータから学習した不特定ユーザモデルを用いて認識する．しかし，3.2 節で述べたように，環境や人体（指）からの磁気ノイズにより，提案デバイスは定常的に影響を受ける．また，ノイズの特徴は環境や人によって異なるため，不特定ユーザモデルを用いた場合精度の低下を引き起こすだろう．このノイズによる影響を抑えるため，不特定ユーザモデルをエンドユーザに適応させ，ユーザ適応モデルを構築する．具体的

© 2015 Information Processing Society of Japan

には，MLLR 適応（maximum-likelihood linear regression adaptation [7]）を用いて不特定ユーザモデル（HMM）内のガウス分布の平均を線形変換する．すなわち，テストデータを用いて，HMM 内のそれぞれの状態がテストデータを生成するもっともらしさが高くなるよう，その出力分布の変換を行う．変換後の平均 $\hat{\boldsymbol{\mu}}$ は，$\hat{\boldsymbol{\mu}} = \boldsymbol{A}\boldsymbol{\mu} + \boldsymbol{b} = \boldsymbol{W}\boldsymbol{\xi}$ のように与えられる．$\boldsymbol{\mu}$ は変換前の平均，$\boldsymbol{A}$ は $k \times k$ の変換行列，k は特徴ベクトルの次元数，$\boldsymbol{b}$ はバイアスベクトルを表す．$\boldsymbol{W}$ は $k \times (k+1)$ の変換行列であり，$\boldsymbol{W} = [\boldsymbol{b}\ \boldsymbol{A}]$ のように分解される．また，$\boldsymbol{\xi}$ は拡張平均ベクトルである $\boldsymbol{\xi} = [1\ \mu_1\ \mu_2 \cdots \mu_k]^T$．不特定ユーザモデルとテストデータのミスマッチを減らすような $\boldsymbol{W}$ を EM アルゴリズムを用いて推定する．そして，推定された変換行列を用いて，不特定ユーザモデルをエンドユーザに適応させる．

5. 評価実験

3 人の実験参加者（A，B，C）から，参加者の家で取得したセンサデータを用いて，認識手法の評価を行う．それぞれの参加者ごとに，参加者から得られたトレーニングデータで認識モデルを学習し，同様に参加者から得られたテストデータを学習したモデルで認識する．また，参加者間でのトレーニングデータの共有に関しても検証を行う．すなわち，ある参加者のテストデータを，他の複数の参加者のトレーニングデータで学習したモデル（ユーザ非依存モデル）を用いて認識する．ユーザ非依存モデルを用いれば，エンドユーザは自身でトレーニングデータを用意する必要がない．さらに，ユーザ非依存モデルをそれぞれの参加者のテストデータを用いて，その参加者に適応させることでユーザ適応モデルを構築する．そして，ユーザ適応モデルを用いてテストデータを認識する．

5.1 データセット

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提案手法の性能評価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つねにモニタリングしておく必要があるため，こ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．そこで，センサデータを文献 [1] で述べられている手法を用いて収集する．具体的には，参加者は与えられたワークシートに従って行動（電化製品の利用）を行う．ワークシートでは，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，「部屋を掃除機がけする」，「CD から曲を 1 曲選んで聞く」といったように，ある程度あいまいであるため，参加者はある程度自由に行動できる．それぞれの参加者は，**表 1** に示した電化製品の利用をランダムな順で行うセッションを，右手中指および薬指にデバイスを装着してそれぞれ 12 セッションずつ行った．デバイスは，ケーブルを介して参加者のバックパック内の PC に接続している．デバイスから取得したセンサデータにラベル付けを行うため，参加者にはヘッドマウントカメラを装着してもらった．

表 1 実験で用いた電化製品のリスト
Table 1 Electrical devices used in our experiment.

	電化製品		電化製品
A	デジタルカメラ	H	電動ミル
B	デジタルカムコーダ	I	IH ヒータ
C	ヘアドライヤ	J	ミキサー
D	電動歯ブラシ	K	CD プレイヤ
E	ハンディ掃除機	L	ノート PC
F	電動ドライバ	M	携帯ゲーム機
G	電動シェーバ	N	おもちゃ（車）

実験では一般的な携帯型電化製品の中から，表 1 に示すように，モータやコイル，通信モジュールなどの時間的に変化する磁気を発生すると考えられる部品を内蔵する電化製品を選んだ．表 1 に示す電化製品を用いて，参加者はそれぞれの家庭で実験を行った．ここで，不特定ユーザモデルの性能を検証するため，3 名の参加者は同じ製品を用いて実験を行った．たとえば，それぞれの参加者が用いた電動歯ブラシは，同じ製品モデルの歯ブラシである．電化製品は参加者の家庭内の適切な場所に設置してもらった．たとえば，電動歯ブラシと電動シェーバは洗面台に置いてもらった．また，デジタルカメラやデジタルカムコーダなどのさまざまな場所で利用する電化製品に関しては，家庭内や家の外などのさまざまな場所で使ってもらうように指示した．

表 1 に示すいくつかの電化製品の利用について簡単に説明する．「デジタルカメラ」に関しては，3.2 節で述べたように，カメラレンズのモータが稼動しているときのみしか磁場の変化が見られたかったため，そのときのみをデジタルカメラの利用と定義した．実験で用いた「CD プレイヤ」は，ポータブル CD プレイヤであり，その本体にあるボタンによりプレイヤを操作してもらった．「ノート PC」の利用では，Google 検索で Yahoo!ニュースを検索してもらい，ニュースの記事を読んでもらった．「携帯ゲーム機」として，ソニー PlayStation Portable を用いた．実験で用いた「おもちゃ（車）」は，ケーブルによりリモコンと車が接続しているものである．

5.2 実験結果：ユーザ依存モデル

ユーザ依存モデルの評価のために，Leave-one-session-out 交差検定を行った．すなわち，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 11 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．このとき，テストデータとトレーニングデータは，同じ参加者の同じ指に装着したデバイスから得られたものである．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平均

© 2015 Information Processing Society of Japan

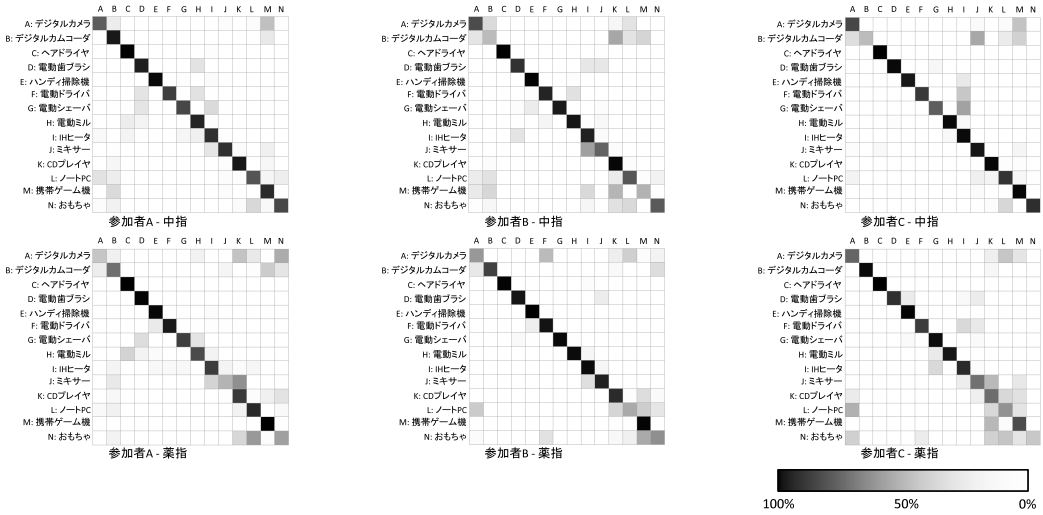


図 8 ユーザ依存モデルを用いたときの認識結果から求めた混同行列

Fig. 8 Visual confusion matrices of the three participants when we use user-dependent models.

表 2 ユーザ依存モデルを用いたときの，それぞれの参加者ごとの認識精度（F 値）

Table 2 Recognition accuracies (overall F-measure) in percentages for each participant with user-dependent models.

指	参加者	精度（%）
中指	A	83.7
	B	75.6
	C	84.0
薬指	A	78.1
	B	81.8
	C	75.5

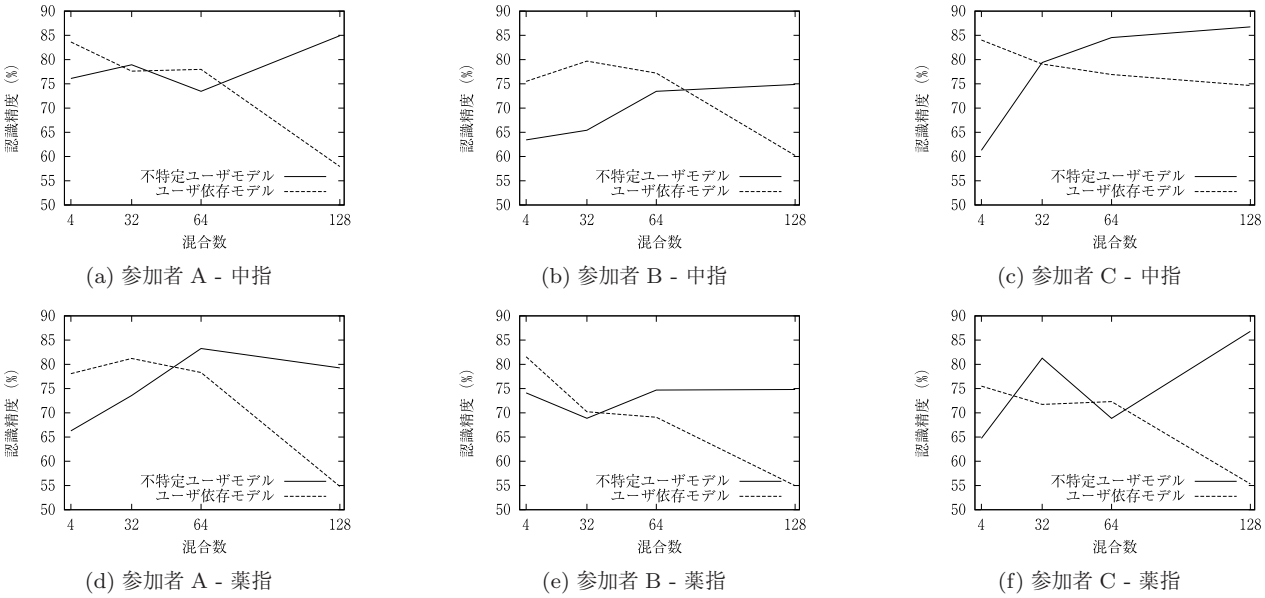
F 値を用いた．**表 2** にそれぞれの参加者の指ごとの認識精度を示しており，それぞれの結果において 80%程度の高い精度を示していた．それぞれの指の精度には大きな違いはなかったものの，中指の精度（平均 81.1%）は薬指の精度（平均 78.5%）を若干上回っていた．

図 8 に，3 人の参加者の認識結果の混同行列を示す．混同行列の各セルの色は，あるクラスに属するインスタンスが，分類器によりどのクラスにどの程度の割合で分類されたかを示している．色が濃いほど割合が高く，割合と色の濃さとの対応を図 8 右下部に示している．混同行列の対角成分の色が濃いほど，インスタンスが正しいクラスに分類されていることを示す．結果から，モータなどの強い磁場を発生する部品を含む電化製品（電動歯ブラシ，電動シェーバ，ヘアドライヤなど）に関する認識精度が高いことが分かる．一方，デジタルカメラやおもちゃ（車）などの強い磁場を発生しない電化製品の精度は，強い磁場を発生するものと比べると低かった．おもちゃのリモコンは，モータなどの強い磁場を発生する部品は含んでおらず，操作のためのボタンや導線のみしか含んでいない．参加者の電化製品の持ち方によっては，このような電化製品からの磁場をとらえることができていなかった．また，ノート PC に関する精度も低い場合が見られた．ノート PC には，CPU や HDD などの強い磁場を発生する部品が含まれる．しかし，それらの部品はノート PC 内に分散して配置されているため，PC に対する参加者の手の位置によっては，磁場をとらえることができていなかった．さらに，ミキサーに関する精度も低い場合が見られた．実験では固定型のミキサーを用いていた．ある参加者はミキサーを使うとき，ミキサーを手に取らず，机上などに設置されたミキサーのボタンを押していた．すなわち，ミキサーと手の位置が固定されていないため，ミキサーの利用ごとに得られるセンサデータの特徴が異なることがあった．一方，手に取って使う電化製品に関する精度は高かった．その中でも，ヘアドライヤ，電動歯ブラシ，ハンディ掃除機などの強い磁場を発生する電化製品に関する精度は特に高かった．手に取って利用する電化製品は，電化製品と手の位置関係が大きく変わらないため，利用ごとに得られるセンサデータの特徴も大きく変わることがない．

5.3 実験結果：不特定ユーザモデル

不特定ユーザモデルの評価のために，Leave-one-participant-out 交差検定を行った．すなわち，ある参加者のある指に装着したデバイスから得られたテストデータの評価に，他の参加者の同じ指に装着したデバイスから得られたトレーニングデータを用いる．また，トレーニングデータ量を増やすため，新たな 3 人の参加者に 12 セッションのデータを筆者らの研究環境で取得してもらった．すなわち，1 人の参加者のテストデータを，他の 5 人の参加者から得られたトレーニングデータを用いて学習したモデルを用いて評価する．ただし，新たに追加した 3 人の参加者のデータはテストデータとしては用いない．ここでユーザ

© 2015 Information Processing Society of Japan



(a) 参加者 A - 中指　(b) 参加者 B - 中指　(c) 参加者 C - 中指

(d) 参加者 A - 薬指　(e) 参加者 B - 薬指　(f) 参加者 C - 薬指

図 9 それぞれの状態ごとの混合数を変化させたときの認識精度の遷移

Fig. 9 Transitions of the recognition accuracies when we increase the number of Gaussian mixtures in each state.

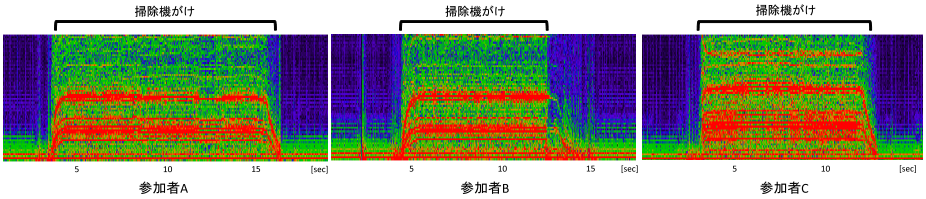


図 10 ハンディ掃除機を利用したときの右手中指に装着したデバイスから得られたセンサデータのスペクトログラム

Fig. 10 Spectrograms obtained from our finger-ring device worn on the right middle finger when the participants used handheld vacuum cleaners.

依存モデルには，出力分布を 4 混合のガウス分布でモデル化した HMM を用いていた．不特定ユーザモデルの評価には，混合数を増やしたモデルを用いる．これは，多くの参加者の電化製品の利用を表現する必要があるためである．

図 9 に，混合数を変化させたときの，ユーザ依存モデルと不特定ユーザモデルの精度の遷移を示す．多くの場合，混合数が多いほど不特定ユーザモデルの精度は高くなる．混合数が 128 のとき，3 人の参加者の中指に装着したデバイスに関する精度の平均は 82.2%，薬指に装着したデバイスに関する精度の平均は 80.3%だった．この結果は，混合数が 4 のときのユーザ依存モデルの精度（81.1%および 78.5%）を上回っていた．これは，5 人の参加者のセンサデータを用いることで，電化製品のさまざまな使い方をモデル化できたためと考える．さらに，MLLR 適応を行いユーザ適応モデルを学習することで，若干認識精度を向上できていた．具体的には，中指と薬指の精度が 82.2%と 80.3%から，84.4%と 81.3%に向上していた．ユーザ適応モデルの詳細な評価については，文献 [12] を参照されたい．

ここで，参加者 B に関する不特定ユーザモデルの認識精度は他の参加者のものと比べて若干低い．下記の要因が，不特定ユーザモデルの精度の低下を引き起こしていると考える．(1) それぞれの家庭における磁場ノイズの特徴は異なる．(2) 提案デバイスは，人体（指）からのノイズにも影響を受ける．そのノイズの特徴は，ユーザ（参加者）ごとに若干異なる．(3) 電化製品の持ち方は参加者ごとに異なるため，参加者から得られるセンサデータも同様に異なる．**図 10** に，参加者 A，B，C がハンディ掃除機を利用したときに得られたセンサデータのスペクトログラムを示す．まず，参加者が掃除機を使っていないときのセンサデータに注目する．このときのセンサデータは，家や身体からの磁気ノイズから影響を受けたものである．これらのセンサデータの周波数的な特徴は類似してるものの，参加者 B のデータには全周波数帯において小さなノイズが見られる（これは，参加者 B の家の近くにある送電塔の影響と考える）．このノイズが，参加者 B の認識精度に影響を及ぼしたと考える．

一方，参加者 C が掃除機を使っているときのピーク周波数の特徴は，参加者 A と B のそれと大きく異なる．これは，参加者 C の掃除機の持ち方が参加者 A と B と異なっていたためと考える．しかし，参加者 C の掃除機の持ち

© 2015 Information Processing Society of Japan

方に似たユーザのセンサデータを含むトレーニングデータを用いて不特定ユーザモデルを学習すれば，参加者 C の掃除機の利用を高い精度で認識できるだろう．一般的に，より多くのトレーニングデータを用いれば，電化製品の多様な利用をとらえた不特定ユーザモデルを学習できる．実際に，ユーザ非依存モデルで認識したとき参加者 C の掃除機の利用に関する精度は高かった（混合数が 128 のとき，中指：81.1%，薬指：85.2%）．

5.4 提案および比較手法の適用可能性

上記の結果のとおり，提案手法により高い精度で認識が可能な電化製品，そうでない電化製品が明らかになった．本節ではこれまでの既存手法と比較して，どのような種類の電化製品に対してどのような手法により高い精度の認識が可能であるかを考察する．ここでは，2 章で紹介した乾電池型センサノードを用いる手法 [11]，音響分析を用いる手法，モーションセンサ（加速度）を用いる手法，ウェアラブルカメラを用いる手法について比較・考察する．ただし，音響，モーションセンサ，ウェアラブルカメラに関して，電化製品の利用の検知のために考案された手法は筆者らの知る限り存在しないため，音響に関してはスマートフォン上のマイクを用いて行動認識を行う研究 [9]，モーションセンサに関しては身体に装着した加速度センサを用いる研究 [1]，ウェアラブルカメラに関しては首掛けストラップ型カメラを用いる研究（Microsoft SenseCam）[4] を想定して考察を行う．

まず，電化製品の内部に含まれる部品に関して考える．**表 3** は，電化製品に含まれる主な磁場を発生する部品の種類ごとに，手法の適用可能性をまとめたものである．ただし，モーションセンサとウェアラブルカメラを用いた手法の適用可能性は内部の部品に関係がないため，ここでは言及しない．提案手法では，高回転モータやコイルなどの大きな電磁波を発する電化製品に対する認識精度が高い．乾電池型センサノードを用いる手法では，電化製品内を流れる電流を直接観測できるため，乾電池で駆動するものであればどのような部品が含まれている電化製品でも高い精度が期待できる．音響を用いた手法では，大きな音が発せられる高回転モータが含まれる電化製品の認識精度が高いと考えられるが，PC 内の HDD などの大きな音を発しない部品もある．また，IH ヒータなどの高出力のコイルを含む電化製品も製品固有の音を発するため，認識精度が高いと考える．

表 4 は，電化製品の駆動形態ごとに，提案手法と比較手法の適用可能性をまとめたものである．乾電池型センサを用いた手法の場合，乾電池駆動の電化製品の利用のみ検知できるが，提案手法では手で持つ電化製品であれば，その駆動形態によらず利用を認識できる．**表 5** は，電化製品の利用形態ごとに，提案手法と比較手法の適用可能性をまとめたものである．提案手法は，常時手に持って使う電化製品の認識精度が高かった．そのような電化製品はユーザの体の近くで利用されるため，マイクや加速度センサ，カメラなどのウェアラブルセンサを用いた場合の認識精度も高

表 3 電化製品内の部品と手法ごとの適用可能性
Table 3 Components included in appliances and availabilities of sensing methods.

	提案	電池センサ	音響
高回転モータ ヘアドライヤ，電動歯ブラシ ...	○	○	△
低回転モータ デジカメ，CD プレイヤ ...	△	○	×
抵抗 懐中電灯，ランタン ...	×	○	×
コイル IH ヒータ ...	○	○	○
IC 回路 TV リモコン， メモリ型携帯音楽プレイヤ ...	×	○	×

表 4 電化製品の駆動形態と手法ごとの適用可能性
Table 4 Types of power source and availabilities of sensing methods.

	提案	電池センサ
コンセント接続 ヘアドライヤ，IH ヒータ ...	○	×
専用バッテリ駆動 デジカメ，デジカム ...	○	×
乾電池駆動 懐中電灯，電動歯ブラシ ...	○	○

表 5 電化製品の利用方法と手法ごとの適用可能性
Table 5 Usage of appliances and availabilities of sensing methods.

	提案	電池センサ	音響	加速度	カメラ
常時接触（把持） ヘアドライヤ，電動シェーバ ...	○	○	○	△	△
一時的接触 音楽プレイヤ，TV リモコン ...	△	○	△	△	△
把持方法可変 電動ミル，ノート PC...	△	○	○	△	△

© 2015 Information Processing Society of Japan

くなるだろう．しかし，加速度センサやカメラを用いた場合，電化製品の把持・利用方法によっては認識精度は下がる．たとえばデジカメを，そのファインダを覗きこむように把持した場合，首から掛けたウェアラブルカメラではそのデジカメを撮影することができない．また加速度センサを用いた場合は，把持・利用方法に特徴のあるものでなければ認識は難しい．たとえば，電動歯ブラシを利用する場合は利用の方法が特徴的であるため，手首などに装着した加速度センサにより認識可能であると考える．しかし，懐中電灯やスマートフォン，デジタルカメラなどの電化製品はその利用の際に手などに装着した加速度センサから得られるデータに特徴がなく，日常生活において得られる加速度データと区別できないと考えられるため認識は難しい．音楽プレイヤや TV リモコンなどの操作の際にのみ手と接触するような電化製品の場合，手と接触する機会が少ないため，提案手法では認識精度が低下する可能性がある．これは，ウェアラブルセンサを用いた他の手法でも同様である．電動ミルやノート PC のような，把持・接触方法が利用中に変化してしまう電化製品の場合でも，ウェアラブルセンサを用いた手法では，把持・接触方法の変化によりセンサデータも変化するため，認識精度が低くなる．

6. おわりに

本論文では，携帯型電化製品の利用を認識するための，指輪型センサデバイスの実装について述べた．提案デバイスにより，電化製品内のモータや電子回路，導線などの部品から発生する時間的に変化する磁場をとらえることができる．評価実験では，実際の家庭において収集したセンサデータを用いて，高い精度で電化製品の利用の認識ができることを確認した．特に，モータを含む電化製品や手に取って利用する電化製品の利用を高い精度で認識できることが分かった．また，参加者間でのトレーニングデータの共有に関しても吟味を行った．その結果，ある参加者のテストデータを，他の参加者から得たトレーニングデータで学習したモデルを用いて，高い精度で認識ができることを確認した．これは，多くの電化製品を把持する方法は人によらず共通しているためと考える．

今後は，単独でバッテリ稼働する無線型センサデバイスを実装し，より現実的な環境での評価実験を行う予定である．また無線型のデバイスにおいては，その電力消費が大きな問題となる．現在の実装では高いサンプリングレートでデータを取得しているが，より低消費電力なセンシングを実現するためには，サンプリングレート抑えたセンシングや圧縮センシング手法が必要になると考える．さらに，消費電力を抑えることによる認識率への影響も検証する必要がある．

参考文献

[1] Bao, L. and Intille, S.S.: Activity recognition from user-annotated acceleration data, *Pervasive 2004*, pp.1–17 (2004).

[2] Gupta, S., Reynolds, M. and Patel, S.: ElectriSense: Single-point sensing using EMI for electrical event detection and classification in the home, *Ubicomp 2010*, pp.139–148 (2010).

[3] Hart, G.: Nonintrusive appliance load monitoring, *Proc. IEEE*, Vol.80, No.12, pp.1870–1891 (1992).

[4] Hodges, S., Williams, L., Berry, E., Izadi, S., Srinivasan, J., Butler, A., Smyth, G., Kapur, N. and Wood, K.: SenseCam: A retrospective memory aid, *Ubicomp 2006*, pp.177–193 (2006).

[5] Jiang, X., Dawson-Haggerty, S., Dutta, P. and Culler, D.: Design and implementation of a high-fidelity AC metering network, *IPSN 2009*, pp.253–264 (2009).

[6] Kim, Y., Schmid, T., Charbiwala, Z. and Srivastava, M.: ViridiScope: Design and implementation of a fine grained power monitoring system for homes, *Ubicomp 2009*, pp.245–254 (2009).

[7] Leggetter, C. and Woodland, P.: Maximum likelihood linear regression for speaker adaptation of continuous density hidden Markov models, *Computer Speech & Language*, Vol.9, No.2, pp.171–185 (1995).

[8] Lifton, J., Feldmeier, M., Ono, Y., Lewis, C. and Paradiso, J.: A platform for ubiquitous sensor deployment in occupational and domestic environments, *IPSN 2007*, pp.119–127 (2007).

[9] Lu, H., Pan, W., Lane, N., Choudhury, T. and Campbell, A.: SoundSense: Scalable sound sensing for people-centric applications on mobile phones, *MobiSys 2009*, pp.165–178 (2009).

[10] Maekawa, T., Kishino, Y., Sakurai, Y. and Suyama, T.: Recognizing the Use of Portable Electrical Devices with Hand-worn Magnetic Sensors, *Pervasive 2011*, pp.276–293 (2011).

[11] Maekawa, T., Kishino, Y., Yanagisawa, Y. and Sakurai, Y.: Mimic Sensors: Battery-shaped Sensor Node for Detecting Electrical Events of Handheld Devices, *Pervasive 2012*, pp.20–38 (2012).

[12] Maekawa, T., Kishino, Y., Yanagisawa, Y. and Sakurai, Y.: Recognizing Handheld Electrical Device Usage with Hand-worn Coil of Wire, *Pervasive 2012*, pp.234–252 (2012).

[13] Maekawa, T., Yanagisawa, Y., Kishino, Y., Ishiguro, K., Kamei, K., Sakurai, Y. and Okadome, T.: Object-based activity recognition with heterogeneous sensors on wrist, *Pervasive 2010*, pp.246–264 (2010).

[14] Patel, S., Robertson, T., Kientz, J., Reynolds, M. and Abowd, G.: At the flick of a switch: Detecting and classifying unique electrical events on the residential power line, *Ubicomp 2007*, pp.271–288 (2007).

[15] Philipose, M., Fishkin, K. and Perkowitz, M.: Inferring activities from interactions with objects, *IEEE Pervasive Computing*, Vol.3, No.4, pp.50–57 (2004).

[16] Rabiner, L.: A tutorial on hidden Markov models and selected applications in speech recognition, *Proc. IEEE*, Vol.77, No.2, pp.257–286 (1989).

[17] Tapia, E., Intille, S. and Larson, K.: Activity recognition in the home using simple and ubiquitous sensors, *Pervasive 2004*, pp.158–175 (2004).

© 2015 Information Processing Society of Japan



前川 卓也 （正会員）

平成 15 年大阪大学大学院工学部電子情報エネルギー工学科卒業．平成 18 年同大学院情報科学研究科博士後期課程修了．同年日本電信電話株式会社入社．平成 24 年 4 月より大阪大学大学院情報科学研究科准教授．博士（情報科学）．本会平成 22 年度山下記念研究賞，日本データベース学会平成 25 年度上林奨励賞等受賞．ACM，IEEE，電気学会，日本データベース学会各会員．



岸野 泰恵 （正会員）

平成 14 年大阪大学工学部卒業．平成 16 年同大学院情報科学研究科博士前期課程修了．平成 19 年同研究科博士後期課程修了．同年日本電信電話株式会社入社．博士（情報科学）．ユビキタスコンピューティング，センサネットワークに関する研究に従事．



柳沢 豊

NTT コミュニケーション科学基礎研究所，客員研究員．工学（博士）．平成 10 年大阪大学大学院工学研究科，博士後期課程修了．同年日本電信電話株式会社に入社，基礎研究所に所属．西日本電信電話株式会社勤務を経て，平成 25 年 9 月より現職．センサネットワーク，ウェアラブルコンピューティング，プログラミング言語の研究に従事．IEEE の会員．



櫻井 保志 （正会員）

平成 3 年同志社大学工学部電気工学科卒業．同年日本電信電話（株）入社．平成 11 年奈良先端科学技術大学院大学情報科学研究科博士後期課程修了．博士（工学）．平成 16〜17 年カーネギーメロン大学客員研究員．平成 25 年熊本大学大学院自然科学研究科教授．本会平成 18 年度長尾真記念特別賞，本会平成 16 年度および平成 19 年度論文賞，電子情報通信学会平成 19 年度論文賞，日本データベース学会上林奨励賞，ACM KDD best paper awards（2008，2010）等受賞．大規模データの探索処理や時系列解析，センサデータ処理，Web マイニングの研究に従事．ACM，電子情報通信学会，日本データベース学会各会員．

© 2015 Information Processing Society of Japan