

乾電池を模したセンサノードによる 携帯型電化製品の利用の認識について

前川 卓也^{†1} 岸野 泰恵^{†1}
柳沢 豊^{†1} 櫻井 保志^{†1}

本稿では、乾電池の形状を模したセンサノードのプロトタイプ的设计と実装を行う。提案するノードは、通常の乾電池と同様に利用することができ、ノードが挿入されている携帯型電化製品とノード間を流れる電流を観測することで、その電化製品の利用を認識できる。近年、われわれは数多くの電化製品に囲まれて暮らしており、何らかの日常行動を行う際にそれらを利用することが多く、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。そのため、ユビキタスセンサやウェアラブルセンサを用いて電化製品の利用を直接的もしくは間接的に観測する研究がこれまでに多く行われてきた。本研究で提案するアプローチでは、センサノードを携帯型電化製品の電池ケースに挿入するだけで、その利用を容易に観測することを可能とする。また、本稿では、ノードから得られるセンサデータを用いて、そのノードがどの電化製品に挿入されているかを識別する手法および、電化製品を用いてどのような操作が行われているかを認識する手法を提案する。
キーワード ユビキタスセンサ、乾電池、行動センシング

Recognizing Portable Electrical Device Usage by using Battery-shaped Sensor Nodes

TAKUYA MAEKAWA^{,†1} YASUE KISHINO^{,†1}
YUTAKA YANAGISAWA^{†1} and YASUSHI SAKURAI^{†1}

We propose and implement a battery-shaped sensor node that can monitor the use of an electrical device into which it is inserted by sensing the electrical current passing through the device. We live surrounded by large numbers of electrical devices and frequently use them in our daily lives, and so we can estimate high-level daily activities by recognizing their use. Therefore, many ubiquitous and wearable sensing studies have attempted to recognize the use

of electrical devices by directly or indirectly monitoring the devices. With our node, we can easily monitor the use of an electrical device simply by inserting the node into the battery case of the device. We also propose a method that identifies into which electrical device the sensor node is inserted and recognizes electrical events related to the device by analyzing the sensor data.

Keywords Ubiquitous sensors, Battery cell, Activity sensing

1. はじめに

日常行動認識は、コンテキスト・ウェアサースのための重要な技術の一つであり、遠隔地の老人の見守り、健康管理、電化製品の自動化などへの応用が期待されている。そのためこれまでに、身体に装着したセンサ（ウェアラブルセンサ）を用いた行動認識研究が多く行われてきた^{1),6)}。ウェアラブルセンサを用いたアプローチは、屋内外を問わずユーザの行動を観測できるが、日常生活においてユーザはセンサを身体に装着する必要がある。一方で、屋内環境に設置したRFIDタグやスイッチセンサなどのユビキタスセンサを用いて行動認識を行う研究も多くある^{9),11)}。このアプローチでは、ユーザはセンサを装着する必要はないが、環境に数多く設置されたセンサノードをメンテナンスする必要がある。また、機械学習を用いる行動認識手法の多くは、ユーザが自身で自身の環境で用意したトレーニングデータを必要とする。

上述のように、多くの行動認識手法は以下に示すようなコストをユーザに強い。

- 設置に関わるコスト: ユビキタスセンサを用いる場合、ユーザは自身の環境に数多くのセンサノードを適切に設置する必要がある。多くの場合、どのノードがどの日常物に添付されているかをあらかじめ関連付けする必要がある。
- メンテナンスコスト: 多くの場合、センサノードの電池を定期的に交換する必要がある。また、故障したノードを交換する必要もある。
- 日常的な利用に関わるコスト: ユーザは日常的にセンサノードを装着したり、ノードが添付された日常物に囲まれて生活しなければならない。また、屋内に設置されたノードは家庭内の美観を損なう。
- 教師あり学習に関するコスト: 多くの行動認識手法は、ユーザの環境で取得されたラベル

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

ありトレーニングデータを必要とする。

一方で、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。われわれ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。これまでに、ウェアラブルセンサやユビキタスセンサを用いて電化製品の利用を認識する研究が行われてきたが、その多くが上記に示したようなコストをユーザに強いる。本稿では、生活において日常的に使われるモノの形状を模したセンサノードを用いて、上記のコストを抑えつつ、ユーザによる電化製品の利用を観測する。具体的には、乾電池型センサノード（例えば単三電池型など）を用いて、そのノードが挿入されている携帯型電化製品の利用を認識する。例えば、ノードをデジタルカメラの電池ケースに挿入したとき、ノードから得られるセンサデータを用いて、いつカメラの電源がオンになったか、いつカメラで写真が撮られたかなどのイベントを認識する。乾電池型センサノードは、電化製品内（ノード内）を流れる電流値を観測するセンサと共にバッテリーを備え、ユーザはノードを通常の乾電池と同様に利用することができる。すなわち、乾電池型センサノードを通常の電池の代わりに電化製品に挿入するだけでノードを設置できるため、その設置コストは小さい。また、ノードは電化製品の電池ケース内に挿入されるため、家庭内の美観を損ねることはない。ここで、ノードを用いて電化製品の利用を認識するためには、どのノードをどの電化製品に挿入したかを示す関連付けを行なう必要がある。本稿では、ノードから得られたセンサデータを用いて、電化製品のイベントを認識するだけでなく、ノードがどの電化製品に挿入されているかも自動的に認識する手法の提案を行なう。提案手法はトレーニングデータを必要とする機械学習のアプローチを用いる。しかし、ノードが観測する電化製品内を流れる電流の特徴は電化製品ごとに固有であり、ユーザの環境ごとに固有ではない。したがって、ユーザごとに自身の環境でトレーニングデータを収集する必要はない。すなわち、トレーニングデータをユーザ間で共有できる。一方、ノード内のバッテリーが消耗した際、ユーザはそのバッテリーを充電したり取り替えたりするコストが必要となる。しかし、電池の交換や充電は通常の電池を電化製品に用いる際にも同様に発生するコストであり、ノードを用いることによる追加のコストは発生しない。ただし、電池の交換や充電の周期を早めないためにも、ノードは省電力設計である必要があるだろう。

本稿では、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、乾電池型センサノードのプロトタイプの実装について述べる。その後、センサノードがどの電化製品に挿入されているかを識別、および、電化製品のイベント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なう。

2. 関連研究

1章で述べたように、電化製品の利用の認識にはユビキタスセンサやウェアラブルセンサが用いられる。文献4)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。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なうことができるが、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、家庭内の電気系統を観測する少数のセンサを用いて、家庭内の電気の利用を検知する研究も行われている^{2),8)}。具体的には、電気系統上のノイズを観測し、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認識する。一方、本稿で提案する乾電池型センサノードは、電気系統に接続されていない携帯型の電化製品の利用を認識する。本研究のコンセプトに最も近い研究が、電源タップ型のセンサノードを用いた研究である^{3),5)}。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。ユーザはタップ型ノードを通常のタップと同様に利用できるため、ユーザの環境にノードを容易に導入できる。

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7)で実現されているシステムでは、手に装着した磁気センサを用いて、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。1章で述べたように、ウェアラブルセンサを用いたアプローチは屋内外を問わずユーザの行動を観測できるが、センサの装着に関わるコストが大きい。

3. 乾電池型センサノードのプロトタイプの実装

本章では、乾電池型センサノードのプロトタイプの実装と実装を行なう。そして、実装したノードから得られたセンサデータを用いて、ノードが挿入されている電化製品の識別および、電化製品のイベントの認識を行なう。ここで、携帯電話などの近年の多くの携帯型電化製品は、あらかじめ内蔵した充電電池により駆動している。しかし、一次電池の世界市場規模は依然大きく（2010年において1兆2000億円）、拡大を続けている。また、われわれの日常生活の中にも、充電式の単三・単四電池は広まっており、われわれはそのような乾電池で駆動する数多くの電化製品に囲まれて暮らしている。さらに、乾電池にセンサを組み込むことで、乾電池に新しい付加価値を付けることができるだろう。

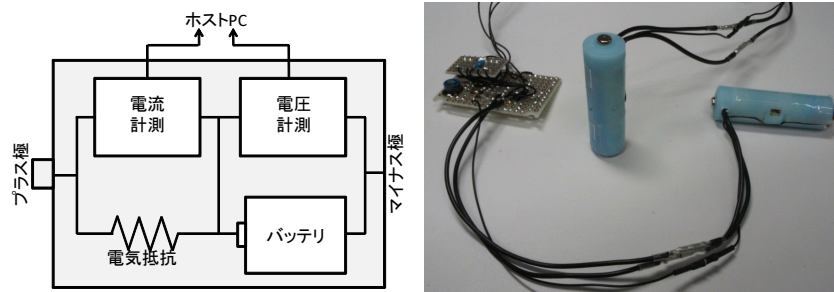


図 1 (a) プロトタイプセンサノードの回路図, (b) プロトタイプセンサノードとセンサボード.

3.1 設計と実装

上述したように、実装するセンサノードは、電池のように放電機能もち、電流計のようにノードと挿入されている電化製品間を流れる電流値を計測する。また、ノードに含まれるバッテリーの電圧値も計測する。電圧を計測する理由については後述する。図 1(a) は、乾電池型センサノードのプロトタイプ回路図である。ノードはバッテリーと抵抗を含み、抵抗を流れる電流を約 1000Hz で計測する。また、含まれるバッテリーの電圧も同様のサンプリングレートで計測する。センサノードはプロトタイプであるため、ノードは有線ケーブルとセンサボードを介してホスト PC にセンサデータを送信する。図 1(b) に、プロトタイプの単三電池型センサノードとセンサボードを示す。また、単二および単一型センサノードも実装している。

3.2 センサデータの例

図 2 に、いくつかの携帯型電化製品にセンサノードを挿入し、電化製品を操作したときに得られた時系列センサデータを示す。図 2(a) 上部のグラフは、電動歯ブラシから得られた時系列センサデータを示し、X 軸は時間を、Y 軸は電流値 (mA) を示す。歯ブラシのスイッチを入れた直後に突入電流が見られ、その後、特徴的な周波数の波形が見られる。これは、歯ブラシ内のモータによるものと考えられる。図 2(a) 下部のグラフは、上部の時系列データから求めた周波数スペクトログラムである。スペクトログラムでは歯ブラシの駆動中に周波数のピークが見られ、これは時系列データの特徴的な周波数によるものである。このような周波数的な特徴は、ノードが挿入されている電化製品の識別や、電化製品のイベントの認識に有用だろう。図 2(b) 上部のグラフは、懐中電灯から得られた時系列センサデータであり、スイッチを入れた直後に突入電流が見られる。その後の懐中電灯点灯中のセンサデータ

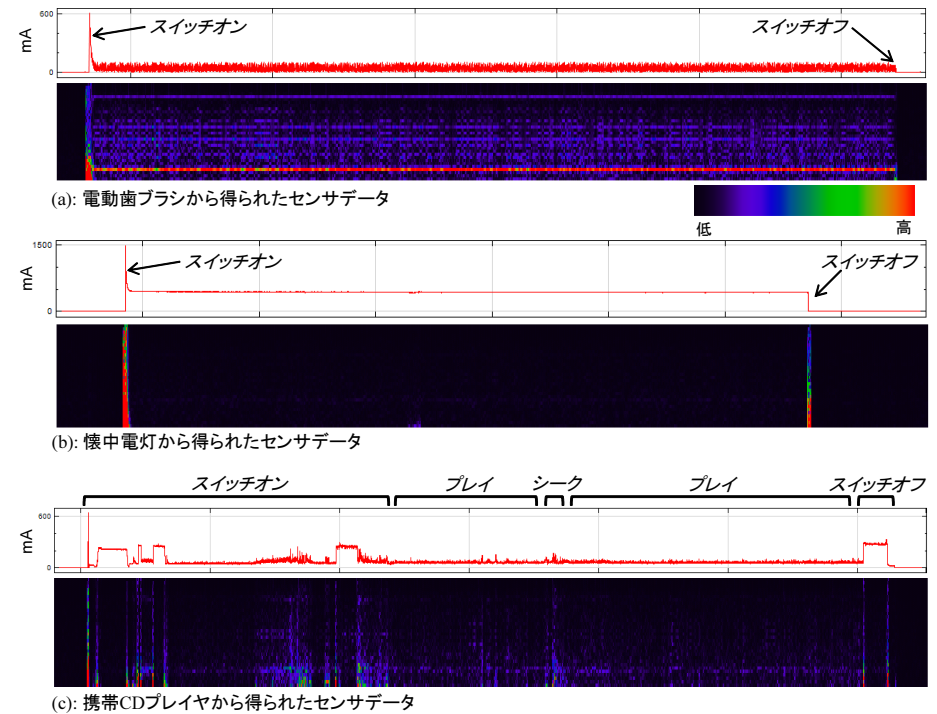


図 2 センサデータの例。上部のグラフは時系列データを、下部のグラフは周波数スペクトログラムを示す。

の値に大きな変化はない。図 2(b) 下部のスペクトログラムでは、懐中電灯点灯中に周波数のピークは見られない。これは、センサデータの値に大きな変化がないためである。図 2(c) 上部のグラフは、携帯 CD プレイヤから得られた時系列データであり、「スイッチオン」、「プレイ」、「シーク」などの CD プレイヤに関するイベントも示している。歯ブラシや懐中電灯とは異なり、CD プレイヤの起動には時間がかかっており、その後音楽が再生される。FF や RW ボタンを押すと、次や前の曲のシークの際に発生する波形の変化が見られる。また、CD プレイヤの終了にもある程度時間がかかっている。図 2(c) 下部に、そのスペクトログラムを示す。これらのグラフに示すように、CD プレイヤから得られたデータは時間的な変化が大きいため、イベントの認識にはその時間的な変化をモデル化する必要があるだろう。

電動歯ブラシや電動シェーバ、携帯掃除機、電動ドライバなどの、いくつかの電化製品は




図3 電動歯ブラシから得られたセンサデータ。歯ブラシの駆動中にその姿勢を変化させている。




図4 満充電のバッテリー、もしくは消耗したバッテリーを用いたときの、携帯 CD プレイヤ (a, b) と懐中電灯 (c, d) から得られたセンサデータ。

モータを内蔵している。モータの回転は、さまざまなモノや現象から影響を受ける。例えば、モータの回転は重力により微小な影響を受けるため、電化製品の重力方向に対する姿勢が変わったとき、その回転にも変化が起こるだろう。その回転の変化により、電化製品を流れる電流値も影響を受ける。図3上部に示すグラフは、電動歯ブラシから得られた時系列センサデータであり、下部はその周波数スペクトログラムである。図に示すようなタイミングで歯ブラシの姿勢を90度回転させており、ピーク周波数がそれにより変化していることが分かる。機械学習のアプローチを用いてイベントを認識するためには、ユーザによる実際の利用に則して電化製品の姿勢などを変えながらトレーニングデータを収集する必要があるだろう。

電化製品内の電池は消耗と共に電圧が低下し、電化製品を流れる電流値にも影響を及ぼす。図4は、CDプレイヤーと懐中電灯から得られたセンサデータを示す。これらは、共に2つの単三電池で駆動する。図4(a)は、満充電の電池を用いた際のCDプレイヤーから得られたセンサデータを示し、2つの電池の電圧の合計は3.097Vである。一方、図4(b)は、消耗した電池を用いた際の同じCDプレイヤーから得られたセンサデータを示し、2つの電池の




図5 提案手法の概略。

電圧の合計は2.689Vである。2つの時系列データは類似しているものの、後者の方がデータの値が若干小さい。図に示すように、プレイヤーのスイッチを入れた直後の値は、前者が242mA、後者が220mAとなっている。また、図4(c)は、満充電の電池を用いた際の懐中電灯から得られたセンサデータを示し、2つの電池の電圧の合計は3.161Vである。一方、図4(d)は、消耗した電池を用いた際の同じ懐中電灯から得られたセンサデータを示し、2つの電池の電圧の合計は2.654Vである。図に示すように、懐中電灯のスイッチを入れた直後の電流値は、前者が491mA、後者が430mAとなっている。上述のように電池の電圧値によって得られる電流値は異なる。機械学習のアプローチを用いて電化製品のイベントの認識を行う場合、この問題に対処する必要があるだろう。この問題には2つの解決法が考えられる。1つ目は、さまざまな電圧の電池を用いてトレーニングデータを作成すること、2つめは、電池の電圧値に依らない特徴を算出して認識に用いることである。

4. 提案手法

センサノードから得られたセンサデータを用いて、ノードが挿入されている電化製品の識別と、電化製品の操作(イベント)を認識する。図5に提案する認識手法の概略を示す。まず、センサノードから得られたデータから特徴抽出を行ったあと、抽出された特徴ベクトルを用いて、電化製品およびイベントの認識を行う。認識のため、得られた特徴ベクトルと、それぞれの電化製品ごとに用意したモデルセットを比較する。電化製品のモデル化には、隠れマルコフモデル(HMM)を用いる。以下に手法の詳細を述べる。

4.1 特徴抽出

時系列の電流値データを扱うため、スライディング時間窓ごとに特徴ベクトルを求める。64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章で述べたとおり、FFT成分や電流値の情報は電化製品やイベントの認識に有用だろう。そこで、窓ごとに求めた

FFT 成分と電流値の平均値を特徴として用いる．さらに，電流値の変化量を捉えるため，その分散とエネルギーも特徴に用いる．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 の直流成分は除いている．

3.2 章で述べたように，電池の電圧値に応じて電流の値は変化する．この問題に対処するため，電化製品の電気抵抗を考慮した特徴抽出を行う．ある操作が行われている（イベントが起こっている）ときの，センサノードの電池（バッテリー）の電圧 V と電池に流れる電流 I ，および，電化製品の抵抗 R との関係は $V = IR$ のように表わされる． $R = V/I$ は電化製品（のイベント）にのみ依存するため，センサから得られる電圧値と電流値から求められる R を特徴として求める．ただし， I がゼロのとき， R は無限大になってしまうため，実際は $1/R$ を特徴として用いる．この特徴抽出手法の効果を，図 4 の例を用いて説明する．まず，図 4(a) と (b) に示す CD プレイヤから得られたセンサデータに注目する．図 4(a) と (b) の矢印で示されている電流値は，それぞれ 242mA と 220mA であり，10.0% の差がある．一方，図 4(a) と (b) の $1/R$ の値は，それぞれ 0.0782 と 0.0819 であり，差は 4.6% にまで減少している．図 4(c) と (d) の矢印で示されている懐中電灯の電流値は，それぞれ 491mA と 430mA であり，14.2% の差がある．一方，図 4(c) と (d) の $1/R$ の値は，それぞれ 0.155 と 0.160 であり，差は 3.2% にまで減少している．電流値の差は，電化製品内のレギュレータ IC の特性，気温，同じ製品に挿入されている他の電池との電圧差などのその他のさまざまな要因にも影響される．しかし， $1/R$ の特徴を用いるだけでも，電流の差を大きく減少できていることが分かる．ここで，直列の n 個の乾電池を含む電化製品を想定する．このとき，電化製品に挿入した 1 つのノードから得られるセンサデータから求めた I/V の値は，実際には n/R に対応する．これは，センサノードが自身に含まれるバッテリーのみの電圧値しか測定できないためである．以上のように，合計 36 の特徴 ($32+1+1+1+1$) が窓ごとに抽出され，特徴ベクトルが作成される．

4.2 HMM を用いた認識手法

センサノードから得られたデータから，特徴ベクトルの系列が抽出される．この系列を用いて，ノードが挿入されている電化製品を識別するとともに，それぞれの特徴ベクトルを電化製品の適切なイベントのクラスに分類する．図 5 に示すように，提案手法は特徴ベクトル系列と，あらかじめ電化製品ごとに用意したモデルセットとを比較することで，電化製品の識別とイベントの認識を同時に行う．モデルセットは，あらかじめ用意したトレーニングデータを基に学習する．モデルセットは，電化製品のイベントごとに用意した left-to-right

HMM から構成される．HMM の観測変数は特徴ベクトルに対応し，隠れ変数はイベントの内部状態に対応するとする．モデルでは，隠れ変数 y_t は以前の隠れ変数 y_{t-1} のみに依存し，時刻 t の観測変数は y_t のみに依存する．そのため，イベントの時間的な変化をモデル化するのに適していると言える．

電化製品の識別およびイベントの認識手法について詳細に説明する．あるモデルセットに着目し，取得した特徴ベクトル系列をそのモデルセットを用いて認識するとする．すなわち，そのモデルセットに対応する電化製品に，ベクトル系列が得られたセンサノードが挿入されていると仮定し，認識を行う．具体的には，Viterbi アルゴリズム¹⁰⁾を用いて，最も尤度（スコア）の高い HMM 内および HMM 間の状態遷移系列を求める．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（イベント）に分類されるか分かる．モデルセットにはイベントに対応する複数の HMM が含まれているため，モデルセット内の HMM 間の状態遷移も想定している．すなわち，ある HMM の最後の状態から他の HMM の最初の状態への遷移も，状態遷移系列を求める際に考慮する．例えば CD プレイヤのモデルセットでは「プレイ」の HMM の最後の状態からその他の HMM の最初の状態への遷移などが起こりうる．このような HMM 間の遷移を考慮することで，イベント間の遷移を表現できる．ここで，あらかじめ用意した文法を用いることで，イベント間の遷移を指定することができる．例えば，デジタルカメラのモデルセットでは「スイッチオン」のイベントの後に「オン」のイベント（電源がオンの状態）が必ず起こるという文法などを指定することができるだろう．次章では，それぞれのモデルセット（電化製品）ごとに文法を作成し，その効果について評価する．

上述したように，あるモデルセットを用いてセンサノードから得られた特徴ベクトル系列を認識する際，Viterbi アルゴリズムは最も尤度の高い状態系列とそのスコアを出力する．そこで，最も高いスコアをもつモデルセットに対応する電化製品を，そのノードが挿入されている電化製品として推定する．上記のような手順により，電化製品の識別と電化製品に関するイベントの認識を同時に行うことができる．

5. 評価結果

5.1 データセット

実験のため，表 1 に示すように乾電池で駆動する携帯型電化製品を多数用意した．表 1 に，それぞれの電化製品ごとのイベントも示している．それぞれの電化製品は，電源オフを示す「オフ」イベントを含む．また，CD プレイヤやデジタルカメラ，携帯型 TV などの

表 1 実験に用いた携帯型電化製品と、それらに関するイベント。

電化製品	イベント	電化製品	イベント
デジタルカメラ 1	オン, スイッチオン, スイッチオフ, 撮影, ピント合わせ, オフ	CD プレイヤ 1	スイッチオン, スイッチオフ, プレイ, シーク, オフ
デジタルカメラ 2	オン, スイッチオン, スイッチオフ, 撮影, ピント合わせ, オフ	CD プレイヤ 2	スイッチオン, スイッチオフ, プレイ, シーク, オフ
デジタルカムコーダ	オン, スイッチオン, スイッチオフ, 撮影, オフ	携帯 TV1	スイッチオン, スイッチオフ, オン, オフ
掃除機 1	オン, オフ	携帯 TV2	スイッチオン, オン, オフ
掃除機 2	オン, オフ	ランタン	オン, オフ
携帯ゲーム	オン, オフ	懐中電灯 1	オン, オフ
シェーバ 1	オン, オフ	懐中電灯 2	オン, オフ
シェーバ 2	オン, オフ	カセットプレイヤー 1	早送り/巻き戻し, プレイ, オフ
シェーバ 3	オン, オフ	カセットプレイヤー 2	早送り/巻き戻し, プレイ, オフ
電動ドライバ 1	ネジ締め, ライト, オフ	DVD プレイヤ	スイッチオン, プレイ, オフ
電動ドライバ 2	ネジ締め, オフ	半田ごて	オン, オフ
歯ブラシ 1	オン, オフ	ミル	粗挽き, 細挽き, オフ
歯ブラシ 2	オン, オフ	おもちゃ1 (船)	オン, オフ
歯ブラシ 3	オン, オフ	おもちゃ2 (車)	前進, 後進, オフ

起動に時間がかかる電化製品は、「スイッチオン」のイベントを含むとした。一方、懐中電灯や電動歯ブラシなどの起動に時間がかからない製品には、「スイッチオン」のイベントは含まれないとした。また、電流の変化が起こらないようなイベント（電化製品の機能）は無視している。例えば、デジタルカメラやデジタルカムコーダの「ズーム」機能を用いても、「オン」イベント（電源オンの状態）の電流値から変化が見られなかった。これは、電化製品内のレギュレータ IC がその機能に必要な電流を十分に供給できていたためと考えられる。すなわち、電池からレギュレータ IC に供給される電流に変化がなかったものとする。また、数多くの機能をもつ電化製品については、主な機能（イベント）のみに着目している。

筆者らの実験環境において、表 1 に示す 28 の電化製品を用いてトレーニングデータを収集した。それぞれの電化製品に 1 つのセンサノードを挿入し、データ収集を行った。3.2 章に述べたように、実際の利用を再現するように、電化製品の姿勢をさまざまに変化させながらデータを収集した。また、さまざまな残量の電池を用いた。それぞれの電化製品ごとに、30 回ずつの使用を行い、トレーニングデータとした。テストデータは、実際の家庭（家 A, B, C）において収集した。それぞれの家の実験参加者に異なる電化製品を与え（家 A: 10 つの製品, 家 B: 10 つ, 家 C: 8 つ）、センサノードを挿入して使用してもらった。センサデータは文献 1) で用いられている手法を用いて収集した。手法では、実験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「CD プレイヤで音楽を自由に聴く」、「自由に TV 番組を視聴する」など、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を行うことができる。ただし、半田ごてに関しては、半田付けは行わず、半田ごてのスイッチをオンにしてもらっただけとした。ワークシートは、参加者に与えた全ての製品をランダムにひと通り使用するセッションを 10 セッション含む。すなわち、家 A と B では、10 の電化製品をひと通り使用するセッションを 10 セッション行い、家 C では 8 の電化製品をひと通り使用するセッションを 10 セッション行った。最初の家では満充電にしたセンサノードおよび乾電池を用いて実験を行い、実験終了後、再充電を行っていないノードと乾電池を用いて、次の家での実験を行った。ただし、電池が激しく消耗している場合は、満充電したものと取り替えた。参加者による実験の様子はビデオカメラにより撮影し、正解データの作成に利用した。

5.2 評価手法

モデルセットは筆者らの実験環境において収集したトレーニングデータを用いて構築し、提案手法の評価は実験参加者の家で収集したテストデータを用いて行った。すなわち、エンドユーザが自身の家でトレーニングデータを用意しない状況を想定している。提案手法の効果を検証するため、以下の 8 つの手法を評価する。

- HMM: この手法は、4.2 章で述べたように HMM を用いて電化製品のモデル化を行う。この手法は $1/R$ を特徴として用いない。また、モデルセット内の HMM 間の遷移確率は全て等確率であるとする。
- HMM(grammar): この手法は、HMM を用いて電化製品のモデル化を行う。この手法は $1/R$ を特徴として用いない。また、モデルセット内の HMM 間の遷移を求めるとき、電化製品ごとに用意した文法を用いる。拡張 BNF で記述したいいくつかの文法の例を示す。懐中電灯の文法は、(‘オフ’ {‘オン’ ‘オフ’}) のように表わされる。この文法により、「オフ」と「オン」のイベントが順に繰り返されることを指定できる。デジタルカメラの文法は、({‘オフ’ ‘スイッチオン’ ‘オン’ {‘撮影’|‘ピント合わせ’|‘オン’} ‘スイッチオフ’} ‘オフ’) のように表わされる。この文法により、「オフ」、「スイッチオン」、「オン」のイベントが順に起こった後に、「撮影」、「ピント合わせ」、「オン」のイベントが繰り返され、最後に「スイッチオフ」と「オフ」のイベントが起こることを指定できる。
- SVM: この手法は、HMM の代わりに SVM を用いる。電化製品の識別のため、それぞれの特徴ベクトルを電化製品のクラスに分類する分類器を構築する。そして、あるノードから得られた全ての特徴ベクトルの分類結果を基に、多数決を用いてノードが挿入されている電化製品を決定する。ただし、電流の平均値がゼロである特徴ベクトルは、分類器の構築に用

いない。このような特徴ベクトルは「オフ」のイベントに対応し、そのイベントは全ての電化製品に共通して存在するため、電化製品の識別には役立たない。また、それぞれの電化製品ごとに、そのイベントを分類する分類器も構築する。この分類器は、それぞれの特徴ベクトルをイベントのクラスに分類する。HMM を用いた手法とは異なり、この手法は電化製品のイベントの時間的な規則性はモデル化できない。この手法は $1/R$ を特徴として用いない。

- Tree: この手法は、上記の SVM 手法における SVM の代わりに決定木を用いる。この手法は $1/R$ を特徴として用いない。
- HMM-R: この手法は $1/R$ を特徴として用いる。また、モデルセット内の HMM 間の遷移確率は全て等確率であるとする。
- HMM-R(grammar): この手法は $1/R$ を特徴として用いる。また、電化製品ごとに用意した文法を用いる。
- SVM-R: この手法は $1/R$ を特徴として用いる。SVM を用いてモデル化を行う。
- Tree-R: この手法は $1/R$ を特徴として用いる。決定木を用いてモデル化を行う。

5.3 評価結果

5.3.1 電化製品の識別

図 6 に、用いるテストデータのセッション数を増加させていった際の、電化製品の識別精度の遷移を示す。例えばセッション数が 3 のとき、それぞれの家で取得した最初の 3 セッションのテストデータのみを用いて電化製品の識別を行う。あらかじめ 28 種類の電化製品を用意しているため、ランダムで識別したときの精度は 3.6% ($1/28 = 0.036$) である。しかし HMM と HMM(grammar) 手法は、セッション数が 10 のとき 96.4% の精度を達成しており、時間的な規則性をモデル化できない SVM や Tree 手法の精度を大幅に上回っている。またセッション数が 5 以上のとき、HMM-R と HMM-R(grammar) 手法は 100% の精度を達成している (図 6 の右のグラフにおいて、これらの 2 つの手法の精度の遷移は全く同じだった。) $1/R$ の特徴を用いるこれらの 2 つの手法の精度は非常に高く、SVM-R や Tree-R の精度を大きく上回っている。これらの結果により、電化製品に関するイベントの時間的な規則性と電化製品の電気抵抗を考慮することの重要性を確認できた。一般的に、用いるテストデータのセッション数が多いほど識別精度も高くなるだろう。これは、より多くのセンサデータを用いて電化製品の識別に有用な特徴を抽出できるためである。しかし、HMM-R と HMM-R(grammar) 手法はセッション数がわずか 1 のときでも、96.4% の精度を達成していた。この結果から、乾電池型センサノードがある電化製品から別の電化製品に入れ替えられても、かなり早い段階でその新しい電化製品を識別できることが分かる。




図 6 用いるテストデータのセッション数を変化させたときの、電化製品の識別精度の変遷。

表 2 それぞれの家におけるイベントの認識精度 (F 値)

	家 A	家 B	家 C	平均
HMM	0.795	0.807	0.839	0.814
HMM(grammar)	0.861	0.822	0.853	0.845
SVM	0.823	0.834	0.837	0.831
Tree	0.834	0.773	0.908	0.839
HMM-R	0.816	0.809	0.843	0.823
HMM-R(grammar)	0.872	0.865	0.875	0.871
SVM-R	0.821	0.828	0.839	0.829
Tree-R	0.822	0.779	0.889	0.830

5.3.2 イベントの認識

イベントの認識精度の評価では、デバイスの識別結果が全て正しいと仮定して、テストデータに含まれるそれぞれの特徴ベクトルの分類結果から求めた F 値を用いる。また、F 値の算出にはそれぞれの家の全てのテストデータ (10 セッション) を用いた。表 2 に、3 つの家の認識結果および平均の認識結果をそれぞれの手法ごとに示す。HMM 手法の認識結果は、識別モデルを用いた SVM と Tree 手法より劣っていた。これは、HMM のように観測値を出力する確率分布を学習する生成モデルよりも、クラス間の識別面を求めようとしてモデルを学習する識別モデルの方が分類問題において高い精度を示すことが多いためであると考えられる。一方、HMM(grammar) 手法の精度は、HMM, SVM, および Tree 手法の精度を上回っていた。以降で詳細に述べるが、HMM(grammar) 手法は文法を用いることで、分類が困難な紛らわしいセンサデータを出力するような電化製品のイベントの認識に高い

性能を示していた。1/R を併せて用いる HMM-R(grammar) は、さらに高い認識精度を達成していた。

認識結果について、さらに詳細に説明する。HMM と HMM-R 手法の認識結果を検証したところ、ほとんどのイベントに関して、HMM-R の精度が HMM の精度をわずかに上回っていた。これは、1/R の特徴を用いているためであると考えられる。HMM-R と HMM-R(grammar) 手法の認識結果を検証したところ、HMM-R(grammar) の高機能な電化製品 (CD プレイヤ、携帯 TV、DVD プレイヤ、デジタルカメラ、デジタルカムコーダ) に関するイベントの認識精度は HMM-R に比べて大きく向上しており、F 値にして平均 0.122 の向上だった。図 2(c) に示すように、これらのデバイスの「スイッチオン」や「スイッチオフ」イベントに対応するデータは複雑な時系列データとなっている。したがって、HMM-R 手法のこれらのイベントに関する F 値は低かった (平均 0.571)。しかし、「オフ」イベントの後に「スイッチオン」イベントが起こることを指定する文法や、「スイッチオフ」イベントの後に「オフ」イベントが起こることを指定する文法を用いることで、これらのイベントの認識精度を 0.248 向上できていた。

最後に、HMM-R(grammar) 手法でも高い認識精度を達成できなかったイベントについて紹介する。2 つの CD プレイヤに関する「シーク」イベントの精度が低く、CD プレイヤ 1 では 0.139、CD プレイヤ 2 では 0.040 の F 値だった。これは、このイベントに関するトレーニングデータが少なかつたためと考える。図 2(c) に示すとおり、「シーク」イベントの時間はとても短く、トレーニングに十分な数の特徴ベクトルを用意できなかったためと考える。また、カセットプレイヤ 1 の「早送り/巻き戻し」のイベントの精度も低く、0.163 の F 値だった。カセットプレイヤ 1 は軽量だったため、プレイヤを手を持ってトレーニングデータの収集を行っていた。しかし、実験参加者はプレイヤを机の上に置いて操作していた。(筆者らは机の上にプレイヤを置いてトレーニングデータを収集していなかった。) 3.2 章で述べたように、モータの回転は、その重力方向に対する姿勢に応じて影響を受ける。「早送り/巻き戻し」のイベントのセンサデータは「プレイ」のセンサデータに類似していたことも原因の 1 つとなり、筆者らが収集したトレーニングデータで構築したモデルでは参加者によるプレイヤの利用をうまく認識できていなかった。

6. おわりに

本稿では、携帯型電化製品の利用を認識するための乾電池型センサノードのプロトタイプ的设计と実装を行った。また、ノードが挿入されている電化製品を識別し、さらに製品を用

いてどのような操作が行われているかを自動的に認識する手法の提案も行った。さらに、実際の家庭で収集したセンサデータを用いて手法の評価を行い、高い認識精度を達成した。今後は、開発中の無線型のノードを用いて長期間のセンサデータ収集実験を行う予定である。

参 考 文 献

- 1) L.Bao and S.S. Intille. Activity recognition from user-annotated acceleration data. In *Pervasive 2004*, pages 1–17, 2004.
- 2) S.Gupta, M.S. Reynolds, and S.N. Patel. Electrisense: Single-point sensing using emi for electrical event detection and classification in the home. In *UbiComp 2010*, pages 139–148, 2010.
- 3) X.Jiang, S.Dawson-Haggerty, P.Dutta, and D.Culler. Design and implementation of a high-fidelity ac metering network. In *IPSN 2009*, pages 253–264, 2009.
- 4) Y.Kim, T.Schmid, Z.M. Charbiwala, and M.B. Srivastava. ViridiScope: design and implementation of a fine grained power monitoring system for homes. In *UbiComp 2009*, pages 245–254, 2009.
- 5) J.Lifton, M.Feldmeier, Y.Ono, C.Lewis, and J.A. Paradiso. A platform for ubiquitous sensor deployment in occupational and domestic environments. In *IPSN 2007*, pages 119–127, 2007.
- 6) P.Lukowicz, H.Junker, M.Stager, T.Von Buren, and G.Tröster. Wearnnet: A distributed multi-sensor system for context aware wearables. In *UbiComp 2002*, pages 361–370, 2002.
- 7) 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.
- 8) S.N. Patel, T.Robertson, J.A. Kientz, M.S. Reynolds, and G.D. 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.
- 9) M.Philipose, K.P. Fishkin, and M.Perkowitz. Inferring activities from interactions with objects. *IEEE Pervasive Computing*, 3(4):50–57, 2004.
- 10) L.R. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2):257–286, 1989.
- 11) E.M. Tapia, S.S. Intille, and K.Larson. Portable wireless sensors for object usage sensing in the home: challenges and practicalities. In *European Conference on Ambient Intelligence 2007*, pages 19–37, 2007.