

乾電池型センサノード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29日, 採録日 2014年10月8日

概要: 本論文では挿入した携帯型電化製品内を流れる電流値を計測できる乾電池型センサノードの提案およびプロトタイプの実装を行う。我々は数多くの電化製品に囲まれて暮らしているため、電化製品の利用を認識することで、人がどのような行動を行っているかが分かると考えられる。そのため、多くのユビキタスコンピューティングやウェアラブルコンピューティングの研究分野において、電化製品や身体に添付、装着したセンサノード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。一方本研究では、乾電池で稼働する電化製品に提案する乾電池型ノードを挿入するだけで、容易に電化製品の利用を観測できる手法を提案する。また、提案するノードから得られた電流値の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を識別する手法および、どのような電化製品の操作が行われたかを認識する手法も提案する。

キーワード: 電化製品, 電池, センサ

Recognizing the Use of Portable Electrical Appliances Using Battery-shaped Sensor Node

TAKUYA MAEKAWA^{1,a)} YASUE KISHINO^{2,b)} YUTAKA YANAGISAWA^{2,c)} YASUSHI SAKURAI^{3,d)}

Received: April 29, 2014, Accepted: October 8, 2014

Abstract: This paper proposes 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 attaching sensor nodes to the devices directly or by attaching multiple sensors to a user. 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 automatically identifies into which electrical device the sensor node is inserted and recognizes electrical events related to the device by analyzing the current sensor data.

Keywords: electrical devices, battery, sensor

1. はじめに

高齢者の見守りやライフログといった様々な実世界アプリケーションの基盤的技術である行動認識は、ユビキタスコンピューティングの分野において最も注目を集めている技術の1つである。多くの研究では身体に装着したセンサ（ウェアラブルセンサ）を用いて行動認識を行っているが [1], [7], [10], ユーザがつねにセンサを装着する必要がある。一方、環境に設置したセンサを用いる研究も多くあるが、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環境に導入する必要があるため、導入や維持管

¹ 大阪大学大学院情報科学研究科
Graduate School of Information Science and Technology,
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 熊本大学大学院自然科学研究科
Graduate School of Science and Technology, Kumamoto Uni-
versity, 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

理のコストが大きい [12], [14]. また, 日常物にセンサを添付する研究も多くあるが, 家庭内の美観を損ねる [2]. さらに, 多くの行動認識研究では機械学習のアプローチを用いているが, エンドユーザが自身の家庭で学習用訓練データを用意することは負担が大きい. このように, これまでの行動認識手法は, 導入, 維持管理, 美観, 訓練データの用意に関して問題があった.

一方で, ユビキタスコンピューティングの分野において電化製品の利用の認識を行う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いるため, 電化製品の利用を認識することで, 人がどのような行動を行っているかが分かると考えられる. 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. 電化製品の利用の認識にはウェアラブルセンサを用いた手法と環境に設置したセンサを用いる手法がある. たとえば, 文献 [5] では各電化製品に添付した磁気センサや照度センサを用いてそれぞれの利用を認識している. また, 文献 [9] では手に装着した磁気センサを用いて, 手で使っている携帯型電化製品の利用を認識している. しかし, これらのアプローチには前述の導入や維持管理, 装着負荷などの問題が存在する. 一方で, 本研究では乾電池で稼働する携帯型電化製品の利用を, 環境に設置したセンサを用いて上記のコストを抑えて実現する手法を提案する. 具体的には, 本論文では乾電池の形状をしたセンサノードのプロトタイプの実現と, それから得られたセンサデータを用いた電化製品の利用の認識手法を提案する. センサノードはバッテリーを備え, 通常の乾電池と同様に放電機能を持つため, 乾電池で稼働する電化製品に挿入できる. ノードが携帯型電化製品に挿入され, その電化製品が利用されているとき, センサノードは電化製品 (センサ) 内を流れる電流を計測し, そのセンサデータをホストコンピュータに送信する. そして, そのセンサデータを解析することで, そのセンサノードがどの電化製品に挿入されているか, どのような操作が行われたかを認識する.

提案するセンサノードは乾電池の形状をしているため, 通常の乾電池と同様に電化製品に挿入するだけで導入できる. また, ノードは電化製品の電池ソケットに挿入されるため, 屋内環境の美観を損ねることもない. さらに, 電化製品から得られるセンサデータの特徴は家庭に依存しないため, 各エンドユーザが個別に訓練データを用意する必要もない. 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.

2. 関連研究

環境に設置したセンサを用いて電化製品の利用を検知するアプローチとして, 文献 [5] では磁気センサを用いて電源ケーブルに流れる電流を検知したり, 照度センサを用いて照明のオン・オフを検知している. しかし, 個々の電化製品にセンサを添付する必要があるため, 導入のコストが大きい. 一方で, 文献 [3], [11] では電気系統上のノイズを観測することで, 電化製品の利用を検知している. この手法では電気系統を介して電化製品の利用を観測するため, 電化製品にセンサを添付する必要がない. 一方本研究では, 電気系統に接続していない携帯型電化製品の利用の認識を行う. 文献 [4], [6] では, 電源タップ型のセンサデバイスを用いて, タップに接続された電化製品の利用を観測している. この手法は, 日常生活で利用される電源タップと同様に利用できるセンサデバイスを実現している点で, 本研究と類似している.

文献 [8], [9] では, ウェアラブルセンサを用いて携帯型電化製品の利用の認識を行っている. 具体的には, 手に磁気センサを装着することで, 電化製品内のモータなどから発せられる時間的に変化する磁場や, 磁石などから発せられる定常的な磁場をとらえ, そのセンサデータを用いて利用の認識を行っている. これらの研究ではウェアラブルセンサを用いているため, ユーザがセンサデバイスを装着する必要がある. 一方で本研究の手法ではこのような装着の負担を必要としないが, 乾電池を利用する電化製品ごとにセンサデバイスを用意する必要がある.

また, 乾電池を模した形状を持つデバイスも存在する. 「運転じょうず AD^{*1}」は, 乾電池で動作する電車などのおもちゃに挿入するデバイスであり, おもちゃに供給される電力を外部のリモコンから制御することで, おもちゃの動作を遠隔から制御できる. 一方で, 本研究では乾電池型デバイスを用いたセンシングを目的としている.

3. 乾電池型センサデバイス

3.1 プロトタイプデバイスの実装

1章で述べたように, 乾電池型センサノードは放電機能を持つため, 電池を内蔵する. また, ノード内を流れる電流を計測する機能を備える. さらに, ノード内の電池の電圧を計測する機能も備えるが, その理由については後述する. 図 1(a) はプロトタイプデバイスの回路図である. ノードは抵抗と電池を内蔵し, 抵抗に流れる電流を約 1,000 Hz のサンプリングレートで計測する. また, 電池の電圧も同時に計測する. センサノードはプロトタイプであるため, ホストコンピュータにケーブルとボードを介してセンサデータを送信する. ただし, ホストコンピュータは固定設置さ

^{*1} BRAVE Co., Ltd : 運転じょうず AD, http://www.b-brave.co.jp/m_shoukai.html




図 1 (a) プロトタイプノードの回路図. (b) 単 3 形のプロトタイプノード

Fig. 1 (a) Schematic of our prototype sensor node. (b) Our prototype battery-shaped sensor nodes.




図 2 (a) プロトタイプノードの内部. (b) ノードを電化製品（デジカム）に挿入したときの様子

Fig. 2 (a) Inside of sensor node. (b) Inserting sensor node in appliance.

れている PC であっても、ユーザが携帯しているスマートフォンのような携帯端末であってもよいと考える。携帯端末をホストとして用いることで、屋外環境でも携帯型電化製品の利用を観測できる。

図 1(b) は単 3 形のプロトタイプノードとボードであり、単 4 形の電池を内蔵する。単 4 形の電池にはアルカリ電池を用いている。そのほかにも単 2 形と単 1 形のノードも制作している。図 2(a) はプロトタイプノードの内部構造を示す。電池の筐体部には単 4 電池および、正極と負極への接続部が内蔵されている。電流計測用の抵抗と IC はセンサボード上に実装している。電池の両端の電圧と電流計測用 IC の出力はセンサボード背面のマイコンに接続している。また図 2(b) は、提案プロトタイプノードをデジカムに挿入して実際にデータを取得する際の様子を示している。このプロトタイプノードから得られたセンサデータを用いて、4 章ではノードがどの電化製品に挿入されているか、どの操作が行われているかを認識する手法を提案する。

3.2 センサデータ

図 3 は、センサノードを様々な電化製品に挿入した際のセンサデータを示している。図 3(a) 上部は、電動歯ブラシから得られた時系列データであり、X 軸は時刻、Y 軸は電流 (mA) を示す。歯ブラシがオンになり突入電流がみられたあと、特徴的な周期を持つ信号が観測されてい

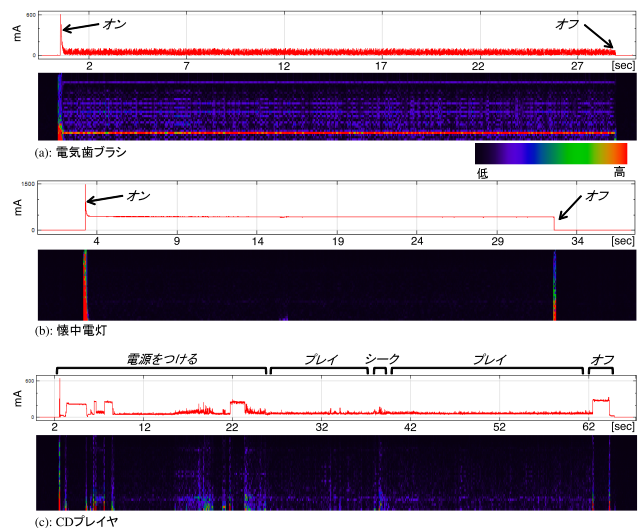


図 3 電流データの例. 上部は時系列データを、下部は周波数スペクトログラムを示す

Fig. 3 Example current sensor data. The upper graphs show original time-series current data. The lower graphs show frequency spectrograms.

る。これは歯ブラシ内のモータにより引き起こされたものとする。図 3(a) 下部はその周波数スペクトログラムを示し、データの特徴的な周波数によるピークがみられる。図 3(b) 上部は懐中電灯から得られた時系列データであり、突入電流のあとに静的な電流値がみられる。図 3(b) 下部はそのスペクトログラムを示しているが、懐中電灯がオンになってもピークがみられないことが分かる。図 3(c) 上部は CD プレイヤから得られた時系列データであり、「電源をつける」、「プレイ」、「シーク」、「オフ」などのイベントが示されている。歯ブラシや懐中電灯とは異なり、CD プレイヤは起動するまで数秒かかっている。その後、CD プレイヤは音楽を再生し始める。早送りや巻き戻しボタンを押すと、次または前の曲をシークする際のノイズがみられる。また、オフボタンを押したあとに、実際に電源が切れるまでも数秒かかっている。この時系列データから分かるように、CD プレイヤのデータは時間的に変化しており、その操作を認識するには時系列変化をモデル化する必要がある。

電動歯ブラシや電動髭剃り、ハンディ掃除機、電動ドライバなどの携帯型電化製品はモータを内蔵する。そのモータの回転が何らかの現象によって妨げられることがある。たとえば、電化製品内のモータの回転は地球の重力によって影響されるため、モータの重力方向に対する姿勢が変化すると、モータの回転に変化を及ぼす。すなわち、モータを内蔵する電化製品の姿勢が変化すると、電流センサデータにも変化が発生する。図 4 上部は電動歯ブラシから得られた電流の時系列データであり、下部はその時系列データから得られた周波数スペクトログラムである。電動歯ブラシを稼働している最中に、その姿勢を 90 度回転させて




図 4 電動歯ブラシから得られたセンサデータ。使用中に歯ブラシの姿勢を変化させている

Fig. 4 Sensor data obtained from a toothbrush. We changed the posture of the toothbrush once while the toothbrush was running.




図 5 内蔵電池が満充電時および消耗時の 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の例

Fig. 5 Sensor data obtained from a CD player (a, b) and a flashlight (c, d) when we used fully charged batteries or exhausted batteries.

いる。スペクトログラムから、歯ブラシを回転させることで、ピークの周波数が若干変化していることが分かる。すなわち、機械学習のアプローチを用いてモータを内蔵する電化製品のイベントを認識するとき、様々な条件下で訓練データを取得しておく必要がある（実際の利用と同様に様々な姿勢で電化製品を利用するなど）。

ここで、電池の消耗について考える。電化製品を利用するにつれて電池の電圧が低下し、それが電化製品（センサノード）を流れる電流値に影響を及ぼす。図 5 に、CD プレイヤと懐中電灯（2つの単三電池で稼働）から得られたセンサデータの例を示す。図 5(a) は、2つの満充電された電池（計 3.097 V）を用いたときに得られたデータであり、図 5(b) は、2つの消耗された電池（計 2.689 V）を用いたときに得られたデータである。これら 2つの時系列データは類似しているが、図 5(b) の電流値は (a) のものに比べて若干小さい。たとえば、CD プレイヤがオンになった直後のデータは、図 5(a) と (b) においてそれぞれ約 242 と 220 mA であり、若干異なっていた。また図 5(c) は、2つの満充電された電池（計 3.161 V）を用いたときに懐中電灯から得られたデータであり、図 5(d) は、2つの消耗された

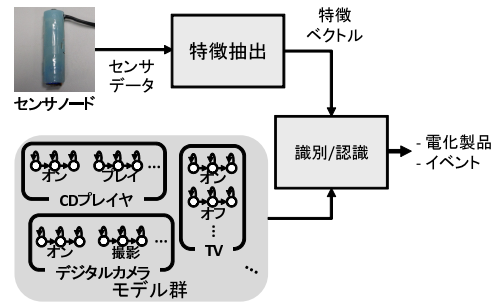


図 6 提案する電化製品の識別とイベントの認識手法の概要
Fig. 6 Architecture of our identification/recognition method.

電池（計 2.654 V）を用いたときに得られたデータである。懐中電灯が点灯しているときの電流値はそれぞれ 491 と 430 mA になっている。このように、電池の電圧値によって観測される電流値は異なるため、機械学習を用いて電化製品および操作の認識を行う際には、この問題を考慮する必要がある。本研究では、電流データと電圧データから、バッテリーの残量に依存しないような特徴量を抽出し、電化製品および操作の認識を行う手法を提案する。

4. 提案手法

プロトタイプセンサノードから得られたセンサデータを解析することで、センサノードが挿入されている電化製品の識別と、その製品の電氣的イベント（どのような操作がなされたか）を認識する。図 6 は提案手法の概要を示す。まずセンサデータから特徴抽出を行ったあと、構築された特徴ベクトルを用いて電化製品の識別とイベントの認識を行う。電化製品の識別とイベント認識を行うため、それぞれの電化製品ごとに用意したモデルと特徴ベクトル系列を比較する。このとき、電化製品のそれぞれの電氣的イベントは、隠れマルコフモデル (HMM) によりモデル化している。以降で詳細を説明する。

4.1 特徴抽出

本研究では時系列の電流データを扱うため、特徴ベクトルをスライディング時間窓ごとに計算する。特徴抽出は、64 サンプルの時間窓から計算された FFT 成分を基に行う。3.2 節で紹介したように、センサデータの周波数成分と電流値が電化製品の識別に有用であることが分かる。そこで、FFT 成分と窓内の電流値の平均を特徴として用いる。また、電流値の変化の大きさを示す分散とエネルギーも特徴として用いる。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。

3.2 節において、観測される電流値は電池の電圧によって変化することが確認された。この問題に対処するため、本研究では電化製品内の電気抵抗を考慮する。電池の電圧 V 、

電池を流れる電流 I ，電化製品の抵抗 R の間には， $V = IR$ の関係が成り立つ． $R = V/I$ は電化製品（のイベント）にのみ依存するため， R を特徴として用いる．提案するセンサノードは電圧と電流を観測可能であるため， R が計算可能である．ここで I が 0 の場合 R は無限大になってしまうため，実際には $1/R$ を特徴として用いる．図 5 を用いて抵抗を用いた方法の効果について検証する．まず，図 5(a) と (b) の CD プレイヤのデータに注目する．図 5(a) と (b) の矢印で示されている電流値はそれぞれ 242 と 220 mA であり，約 10.0% の誤差がある．一方，電流と電圧から計算された $1/R$ の値は，それぞれ 0.0782 と 0.0819 となり，約 4.6% の誤差に縮小した．懐中電灯のデータでは，図 5(c) と (d) における電流値はそれぞれ 491 と 430 mA であり，約 14.2% の誤差がある．一方，電流と電圧から計算された $1/R$ の値は，それぞれ 0.155 と 0.160 となり，約 3.2% の誤差に縮小した．電化製品内の他の乾電池の電圧，電化製品内のレギュレータ IC 変換特性，温度などの問題により，この誤差を完全に解消することは難しいが，単純に $1/R$ を用いるだけでも誤差を大きく低減できていることが分かる．上記のように，それぞれの窓ごとに 36 次元（内訳は，32：FFT，1：平均，1：分散，1：エネルギー，1： $1/R$ ）の特徴ベクトルが抽出される．

4.2 HMM を用いた識別/認識手法

ここでは，センサデータから抽出された特徴ベクトル系列を用いて，データが得られたセンサノードが挿入されている電化製品を識別し，同時にどのような電氣的イベントが起こったかを認識する．図 6 に示すように，あらかじめ電化製品ごとに用意されたモデルと特徴ベクトル系列を比較することで，識別および認識を行う．モデルはラベルあり訓練データを用いてあらかじめ学習しておく．モデルは電化製品ごとに用意し，その電氣的イベントごとに用意した left-to-right HMM を含む．HMM を用いることで，電氣的イベントの時間的変化をとらえることができる．

提案手法を詳細に説明する．手法では，ある電化製品のモデルに注目し，センサノードがその電化製品に挿入されていると仮定し，特徴ベクトル系列をモデルに含まれる HMM 群で認識する．認識には Viterbi アルゴリズム [13] を用いて HMM 間および HMM の状態間の最ももっともらしい遷移系列を求め，その尤度をその電化製品のスコアとして用いる．求められた状態遷移系列から，時刻 t に対応する特徴ベクトルがどの HMM（電氣的イベント）に属するのか分かる．ここで，多くの電化製品は複数の電氣的イベント（HMM）を持つため，HMM 間，すなわちある HMM の最後の状態から異なる HMM の最初の状態への遷移を考慮する必要がある．たとえば CD プレイヤのモデルでは，「プレイ」の HMM から「オフ」の HMM（やその他の HMM）への遷移を考慮する必要がある．このような遷

移を考慮することで，電氣的イベントの遷移を表現することができる．HMM 間の状態遷移はあらかじめ作成した文法情報により定義する．たとえば CD プレイヤのモデルでは，「オン」イベントのあとには「プレイ」のイベントが起こるなどという状態遷移が定義できる．このような文法を電化製品ごとに作成し，その効果を 5 章で検証する．

上述したとおり，Viterbi アルゴリズムにより，電化製品のモデルを用いて特徴ベクトル系列を認識したときの最ももっともらしい状態遷移系列を求めるとともに，そのスコアを計算する．そして，最も高いスコアを持つモデル（電化製品）を，その特徴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電化製品であるとする．上記のように提案手法を用いて，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すると同時に，その電氣的イベントを認識する．

5. 評価

5.1 データセット

評価のために表 1 に示すような携帯型電化製品を用意した．これらは，電器店においてよくみられるものである．また，表 1 にそれぞれの電化製品に関する電氣的イベントも示している．それぞれの電化製品はオフ状態を示す「オフ」イベントを含んでいる．また，TV や CD プレイヤ，デジタルカメラなどの電源オフになるまで時間がかかる電化製品に関しては，「電源を消す」というイベントを含む．これは，電源オフのボタンを押してから実際に電源が切れるまでに対応するイベントである．同様に電源オンになるまで時間がかかる電化製品に関しても，「電源をつける」というイベントを含む．一方，懐中電灯や電動歯ブラシは稼働状態になるまでにほとんど時間がかからないため，「電源をつける」というイベントを含まず，「オン」イベント（オンの状態）のみ含む．このような電化製品の「電源をつける」というイベントは非常に時間が短く，センサデータにラベル付けをすることが難しいため無視した．また，観測される電流値が変化しないようなイベントに関しても無

表 1 実験で用いた電化製品とその電氣的イベント

Table 1 Electrical devices used in our experiment and their electrical events.

電化製品	イベント	電化製品	イベント
デジカメ 1	オン，電源をつける，電源を消す， 写真を撮る，フォーカス，オフ	CD プレイヤ 1	電源をつける，電源を消す， プレイ，シーク，オフ
デジカメ 2	オン，電源をつける，電源を消す， 写真を撮る，フォーカス，オフ	CD プレイヤ 2	電源をつける，電源を消す， プレイ，シーク，オフ
デジカメ	オン，電源をつける，電源を消す， 撮影する，オフ	TV1	電源をつける，電源を消す， オン，オフ
掃除機 1	オン，オフ	TV2	電源をつける，オン，オフ
掃除機 2	オン，オフ	ランタン	オン，オフ
ゲーム機	オン，オフ	懐中電灯 1	オン，オフ
読書機 1	オン，オフ	懐中電灯 2	オン，オフ
読書機 2	オン，オフ	ラジカセ 1	FF/RW，プレイ，オフ
読書機 3	オン，オフ	ラジカセ 2	FF/RW，プレイ，オフ
ドライバ 1	FF/RW，点灯，オフ	DVD プレイヤ	電源をつける，プレイ，オフ
ドライバ 2	FF/RW，オフ	半田ごて	オン，オフ
歯ブラシ 1	オン，オフ	ミル	オン，オフ
歯ブラシ 2	オン，オフ	おもちゃ 1 (船)	前進，オフ
歯ブラシ 3	オン，オフ	おもちゃ 2 (車)	前進，後進，オフ

視した。たとえば、本研究で用いた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、オン状態からいっさいの電流値の変化が起こらなかった。そのため、「ズーム」イベントを無視している。これは、電化製品内のレギュレータ IC がズーム機能に十分な電流を供給できているため、電池がレギュレータに供給している電流に変化がなかったからと考える。また、多数の機能を持つ電化製品に関しては、主な機能のみに注目している。

モデルを学習するための訓練データは、表 1 に示す電化製品を用いて筆者らの実験環境において実験環境の作業員が収集した。作業員は以降で説明するテスト用データを取得した実験参加者とは異なる。作業員は、センサノードを電化製品に挿入して、実際に電化製品の一連の操作を行ってデータを取得した。このとき、実際の利用を想定して電化製品の姿勢を様々に変化させて、それぞれの電化製品ごとに 30 回ずつ一連の操作を行った（すなわち、それぞれの電化製品において約 1 分間利用してもらった）。これにより、姿勢の違いによるセンサデータの変化の問題に対応する。また、電池の残量を様々に変化させて訓練データを収集した。

テスト用データは実際の 3 つの家（家 A, B, C）で、それぞれの環境の住人（実験参加者）が収集した。それぞれの環境の実験参加者にそれぞれ異なる電化製品を渡し（家 A : 10 個, 家 B : 10 個, 家 C : 8 個。詳細は表 3, 表 4, 表 5 を参照）、プロトタイプセンサノードを電化製品に挿入して利用してもらうように依頼した。テスト用データは、Semi-naturalistic collection protocol [1] に従って取得した。Semi-naturalistic collection protocol 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。すなわち、多様なセンサデータを収集することができる。プロトタイプセンサノードはケーブルを介してホストコンピュータに接続しているため、参加者は実験環境の 1 つの部屋においてデータ取得を行った。しかし、参加者には実際に生活の中で利用しているように電化製品を利用してもらうよう依頼した。ただし半田ごてに関しては、実際に半田付けは行わず電源をつけるだけにしてもらった。それぞれの参加者は計 10 セッションずつセンサデータ取得を行った（家 A と B : 10 個の電化製品 × 10 セッション, 家 C : 8 個の電化製品 × 10 セッション）。それぞれのセッションは約 10 分間であり、それぞれのセッションにおいて与えた電化製品をひと通りランダムな順序で 1 回ずつ利用してもらった。最初の家では満充電の電池を用い、その後の家では消費されたその電池をそのまま用いた。ただし、電池がほとんど消耗した場

合は新しい電池に取り替えた。実験の様子は Web カメラにより記録し、正解データのラベル付けに用いた。

5.2 評価手法

それぞれの電化製品のモデルは筆者らの実験環境で得られた訓練データを用いて学習し、提案手法を実験参加者の家で取得したテスト用データを用いて評価した。すなわち、それぞれのエンドユーザはそれぞれの家で訓練データを用意する必要がない。提案手法の効果を検証するため、以下の 8 つの手法を用いて評価を行った。

- **HMM** : この手法は 4.2 節で述べたように HMM を用いて電氣的イベントをモデル化する。この手法は $1/R$ を特徴として用いない。また、HMM 間の状態遷移確率は等しいとしている。

- **HMM (grammar)** : この手法は HMM を用いて電氣的イベントをモデル化する。この手法は $1/R$ を特徴として用いない。またこの手法は、あらかじめ電化製品ごとに作成した文法を用いて HMM 間の状態遷移を求める。拡張 BNF を用いて文法の例をいくつか紹介する。懐中電灯の文法は（‘オフ’ { ‘オン’ ‘オフ’ }）のように記述される。この文法により、「オン」と「オフ」のイベントが順に繰り返されることを表現できる。

またデジタルカメラの文法は、（{ ‘オフ’ ‘電源をつける’ ‘オン’ { ‘写真を撮る’ | ‘フォーカス’ | ‘オン’ } ‘電源を消す’ ‘オフ’ }）のように記述される。この文法により、「オフ」、「電源をつける」、「オン」のイベントが連続して起こり、「写真を撮る」、「フォーカス」、「オン」のイベントが「電源を消す」と「オフ」が起こる前に交互に起こることを表現できる。たとえば、「電源をつける」HMM の最後の状態から、「オン」以外の HMM の最初の状態への状態遷移確率は 0 であり、一方で、「オン」HMM の最初の状態への状態遷移確率は 1 である。また、「写真を撮る」HMM の最後の状態から「フォーカス」、「オン」、「電源を消す」HMM の最初の状態への状態遷移確率はそれぞれ $1/3$ である。一方で、他の HMM への状態遷移確率はすべて 0 である。

- **SVM** : この手法は HMM の代わりに SVM を用いる。この手法では電化製品を識別する分類器を用意する。分類器は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。あるセンサノードから得られた特徴ベクトルの分類結果の多数決により、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する。ただし分類器を学習するとき、電流データの平均が 0 である、すなわち「オフ」に対応する特徴ベクトルは用いない。これは、すべての電化製品に含まれる「オフ」イベントが識別性能を低下させると考えるためである。また、それぞれの電化製品ごとに電氣的イベントを認識する分類器を SVM を用いて構築した。HMM を用いた手法と異なり、この手法は電氣的イベントの時間的变化をモデル化できない。また、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 SVM 手法の SVM の代わりに C4.5 決定木を用いる。また、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。その他の挙動は上記の HMM 手法と同様である。
- **HMM-R (grammar)** : この手法は 1/R を特徴として用いる。その他の挙動は上記の HMM (grammar) 手法と同様である。1/R と文法を併用したこの手法を、本論文の提案手法とする。
- **SVM-R** : この手法は 1/R を特徴として用いる。その他の挙動は上記の SVM 手法と同様である。
- **Tree-R** : この手法は 1/R を特徴として用いる。その他の挙動は上記の Tree 手法と同様である。

5.3 結果

5.3.1 電化製品の識別

図 7 は、電化製品の識別に用いるテスト用セッションの数を変化させたときの識別性能の遷移を示している。たとえばテスト用セッション数が 3 のとき、それぞれの家で得られた最初の 3 セッションのデータを用いて識別を行った。この実験では 28 種類の電化製品のモデルを用意したため、ランダムに推定したときの正解確率は 3.6% ($1/28 = 0.036$) のみである。しかしテスト用セッション数が 10 のとき、HMM と HMM (grammar) 手法は 96.4% の正解率を達成している。これらの手法は電気的イベントの時間的変化をモデル化できない SVM や Tree を大幅に上回っている。ま

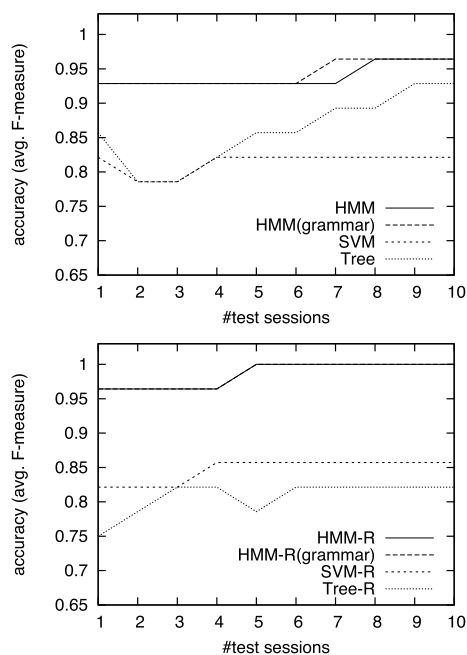


図 7 電化製品の識別に用いるテスト用セッションの数を変化させたときの識別性能の遷移

Fig. 7 Transitions of device identification accuracies when we increase #sessions that are used to identify devices.

た、HMM-R と HMM-R (grammar) 手法はテスト用セッション数が 4 以上のとき、100% の認識率を達成している (図 7 において、この 2 手法の識別精度の遷移は完全に同じであった)。1/R の特徴を用いることで、高い精度での識別ができていた。また、これらの手法は SVM-R と Tree-R を大幅に上回っていた。上記のように、電気的イベントの時間的変化と電化製品内の電気抵抗をとともに用いることで高い精度を達成できることが分かった。また基本的に、多くのセッションのデータを用いることで高い識別性能を達成することができた。これは、単純に十分な量のセンサデータを用いることで識別可能な特徴をとらえることができたためと考える。しかし、HMM-R と HMM-R (grammar) 手法は 1 セッションのテスト用センサデータを用いるだけで 96.4% の識別精度を達成していた。これらの結果から、センサノードがある電化製品から取り外されて、異なる電化製品に挿入されたとしても、すぐにその新しい電化製品を識別できると考える。

5.3.2 イベントの認識

電気的イベントの認識精度を評価するため、電化製品の識別結果がすべて正しいとして、それぞれの特徴ベクトルのイベント分類結果から平均 F 値を求め、評価指標とする。また、F 値は 10 セッションすべてのテスト用センサデータから求めた。表 2 はそれぞれの家における認識精度を示しており、HMM 手法は分類モデルを用いた SVM や Tree 手法に比べて認識精度が若干低いことが分かる。これはクラス間の境界を学習する分類モデルに比べて、HMM のようなデータの分布を学習する生成モデルの分類問題における性能が若干劣ることがあるためと考える。一方、HMM (grammar) 手法は、HMM, SVM, Tree 手法を上回っていた。詳細は以降で述べるが、HMM (grammar) 手法は文法情報を用いることで、時間的に複雑に変化するようなセンサデータを出力する電化製品のイベントに対して高い認識精度を達成していた。文法情報と 1/R をあわせて用いる HMM-R (grammar) 手法は全手法の中で最も高い認識精度を達成していた。

表 3, 表 4, 表 5 はそれぞれの家ごとの詳細なイベント認

表 2 それぞれの家ごとの電気的イベントの認識精度 (平均 F 値)
Table 2 Event recognition accuracies (average F-measure) in each house.

	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

表 3 家 A におけるイベントの認識精度 (F 値)

Table 3 Event recognition accuracies in house A.

		HMM	HMM-R	HMM-R (grammar)
デジカメ 2	オン	0.759	0.796	0.799
	電源をつける	0.513	0.538	0.826
	電源を消す	0.349	0.363	0.97
	写真を撮る	0.38	0.395	0.622
	フォーカス	0.476	0.489	0.591
掃除機 2	オフ	0.975	0.975	0.975
	オン	0.994	0.994	0.994
ゲーム機	オフ	0.982	0.982	0.982
	オン	0.968	0.992	0.992
髭剃り 1	オフ	0.907	0.973	0.973
	オン	0.994	0.993	0.993
ドライバ 1	オフ	0.961	0.958	0.958
	FF/RW	0.99	0.991	0.991
歯ブラシ 1	点灯	0.992	0.991	0.991
	オフ	0.977	0.977	0.977
	オン	0.997	0.997	0.997
CD プレイヤ 1	オフ	0.986	0.988	0.988
	電源をつける	0.497	0.545	0.726
TV1	電源を消す	0.381	0.59	0.76
	プレイ	0.775	0.799	0.922
	シーク	0.088	0.11	0.139
	オフ	0.995	0.997	0.995
ランタン	電源をつける	0.603	0.689	0.851
	電源を消す	0.379	0.357	0.163
ラジカセ 2	オン	0.994	0.997	0.999
	オフ	0.886	0.928	0.957
	オン	0.997	0.997	0.997
平均	オフ	0.983	0.983	0.983
	FF/RW	0.940	0.961	0.961
ラジカセ 2	プレイ	0.954	0.968	0.968
	オフ	0.988	0.988	0.988
平均		0.795	0.816	0.872

表 4 家 B におけるイベントの認識精度 (F 値)

Table 4 Event recognition accuracies in house B.

		HMM	HMM-R	HMM-R (grammar)
デジカメ	オン	0.946	0.929	0.928
	電源をつける	0.707	0.72	0.855
	電源を消す	0.264	0.268	0.784
	撮影する	0.776	0.73	0.792
	オフ	0.988	0.989	0.988
髭剃り 2	オン	0.997	0.995	0.995
	オフ	0.992	0.988	0.988
ドライバ 2	FF/RW	0.991	0.991	0.991
	オフ	0.986	0.986	0.986
歯ブラシ 2	オン	0.996	0.996	0.996
	オフ	0.991	0.991	0.991
CD プレイヤ 2	電源をつける	0.534	0.581	0.652
	電源を消す	0.514	0.627	0.788
	プレイ	0.935	0.941	0.941
	シーク	0.035	0.037	0.04
	オフ	0.989	0.996	0.99
懐中電灯 1	オン	0.995	0.995	0.995
	オフ	0.987	0.987	0.987
懐中電灯 2	オン	0.993	0.994	0.994
	オフ	0.986	0.988	0.988
ラジカセ 1	FF/RW	0.381	0.071	0.071
	プレイ	0.686	0.639	0.639
	オフ	0.878	0.901	0.901
DVD プレイヤ	電源をつける	0.721	0.787	0.995
	プレイ	0.366	0.562	0.99
	オフ	0.989	0.989	0.989
	オン	0.993	0.993	0.993
半田ごて	オン	0.993	0.993	0.993
	オフ	0.984	0.984	0.984
平均		0.807	0.809	0.865

認識精度を示す。多くの電化製品は 2 状態しか持たないため、高い認識精度を達成していた。まず、HMM と HMM-R 手法に着目する。1/R の特徴を用いることで、多くのイベントにおいて若干認識精度が向上しており、表 2 に示すように平均して約 1% 向上している。次に HMM-R と HMM-R (grammar) 手法に着目する。文法を用いることで認識精度が大幅に向上しており、表 2 に示すように平均して約 5% 向上している。特に、CD プレイヤ、TV、DVD プレイヤ、デジタルカメラ、デジタルカムコーダに関して認識精度が大きく向上しており、平均して F 値が約 12.2% 向上していた。図 3(c) に示すように、「電源をつける」と「電源

表 5 家 C におけるイベントの認識精度 (F 値)

Table 5 Event recognition accuracies in house C.

		HMM	HMM-R	HMM-R (grammar)
デジカメ 1	オン	0.751	0.764	0.759
	電源をつける	0.577	0.621	0.801
	電源を消す	0.464	0.639	0.854
	写真を撮る	0.602	0.618	0.835
	フォーカス	0.535	0.515	0.455
掃除機 1	オフ	0.988	0.98	0.988
	オン	0.996	0.996	0.996
髭剃り 3	オフ	0.988	0.988	0.988
	オン	0.997	0.997	0.997
歯ブラシ 3	オフ	0.993	0.993	0.993
	オン	0.994	0.994	0.994
TV2	オフ	0.985	0.985	0.985
	電源をつける	0.613	0.621	0.627
	オン	0.903	0.914	0.922
ミル	オフ	0.723	0.571	0.706
	オン	0.977	0.981	0.981
おもちゃ 1 (船)	オフ	0.998	1	0.988
	前進	0.997	0.997	0.997
おもちゃ 2 (車)	オフ	0.985	0.988	0.988
	前進	0.757	0.752	0.752
	後進	0.661	0.665	0.665
平均		0.974	0.987	0.987
平均		0.839	0.843	0.875

を消す」イベントは複雑な時系列データであり、これらのイベントに関する HMM-R 手法の精度は低く、その F 値は 57.1% だった。しかし、「電源をつける」は「オフ」のあとに起こる、「電源を消す」のあとには「オフ」が起こるなどの文法を用いることで、その F 値を約 24.8% 向上させることに成功していた。

HMM-R (grammar) 手法が高い精度で認識できなかったイベントについて説明する。家 A と B における CD プレイヤの「シーク」の認識精度が低かった。これは、このイベントに関する十分な量の訓練データが用意できなかったためと考える。図 3(c) に示すとおり、「シーク」イベントの時間は短く、訓練データに含まれる特徴ベクトルの数も少なくなる。また、家 A における TV1 の「電源を消す」イベントに関する精度も低かった。このイベントは「オフ」イベントと間違えて認識されていたことが多かった。「電源を消す」イベントにおける電流値は 0 に非常に近かったため、「オフ」イベントと混同したと考える。さらに、家 B におけるラジカセ 1 の「FF/RW」イベントの認識精度も低かった。筆者らの実験環境で訓練データを取得した際、このラジカセは軽量であったため、手でラジカセを持ってデータを取得した。しかし、家 B の参加者は机にラジカセを置いてテスト用データを取得していた。3.2 節で述べたとおり、モータの回転はモータの重力方向に対する姿勢に影響される。そのため、訓練データから学習したモデルでは高い精度で家 B でのラジカセの利用を認識できなかった。

5.3.3 実運用における提案手法の利点

上述のとおり、認識性能において提案手法は比較手法を大きく上回っていた。実際のエンドユーザ環境における利用・運用においても、提案手法は下記のような利点があると考えられる。

訓練データの準備コスト低減：評価実験では、実験環境の作業者が様々な残量の電池を用いて訓練データを取得して

いた。これは、電池の残量に応じて電流量が変化してしまう問題に対処するためであるが、表2のHMMとHMM-Rの結果をみるとHMM-Rの方が精度が高くなっており、単純に様々な残量の電池を用いるだけでは、連続的に変化する電池の残量による電流量の変化に対応できないことが分かる。すなわち1/Rを用いることで、電池を変化させて用意した訓練データが少ない場合でも高い精度で認識が可能となる。

迅速なサービス開始：図7に示すように、SVMやTree手法を用いた場合は製品の認識にある程度時間を要する。1つのテスト用セッションの長さは約10分であり、それぞれの電化製品が約1分ずつ利用されている。すなわち、製品の認識精度が9割に達するまでに7セッションを要するTree手法の場合だと、1分の利用が7回も必要になる。一方、提案手法では1分の利用のみで9割を超える認識精度を達成しているため、認識結果を迅速にアプリケーションに利用できる。

6. おわりに

本論文では、携帯型電化製品の利用を観測するための乾電池の形状をしたセンサノードの提案とプロトタイプの実装を行った。また、ノードが挿入されている電化製品を識別する手法および電化製品の利用（電氣的イベント）を認識する手法の提案も行った。提案手法により、ノードがどの電化製品に挿入されているか、すなわち、どの電化製品が利用されているかを自動的に識別することができる。さらに、実際の家庭で得られたセンサデータを用いて、提案手法の識別/認識性能を検証し、高い性能で識別/認識できていることを確認した。上述のように、本論文では提案した手法を用いて電化製品の利用が認識できることを確認した。また、他のユーザが収集した訓練データを用いて高い精度での認識が達成できることも確認した。すなわち、エンドユーザ自身が訓練データを用意しなくても、サービス運用側が共通の訓練データを用意すれば、高い精度での認識が可能となる。しかし、提案する電池型ノードを用いて美観を保ったセンシングが可能であるか、導入・維持管理コストの低いセンシングが可能であるかを確認するユーザスタディはまだ行っていない。今後は無線型のセンサノードを開発し、そのノードを用いて美観や導入・維持管理に関するユーザ評価を行うことを考えている。

無線型のノードを開発する際には、主に2つの問題を解決する必要があると考える。まず1つ目の問題は、センサと無線通信モジュールのサイズである。無線通信モジュール、センサ、内蔵電池を組み合わせると単3形電池の大きさのノードを製作する必要がある。しかし図1(a)に示すように、提案デバイスの回路図は単純でありセンサ部分の回路は小型化できる。また、無線通信モジュールを内蔵した小型CPUも登場しているため、そのようなモジュールを

用いて小型ノードを実現する予定である。2つ目の問題として、ノードの消費電力があげられる。まず、電流値が0のとき、すなわち「オフ」状態のセンサデータを送信しないことで大幅な消費電力の削減が可能と考える。また、図3や図4に示すように、多くの電化製品からは類似したセンサデータのパターンが連続して得られる。このような類似したパターンを圧縮することで、送信データ量を削減することも考えられる。さらに、今後の課題としてできるだけ多数の電化製品を用いて提案手法の検証を行う予定である。たとえば今回の実験では、デジタルカメラのズーム機能を用いた場合や音楽プレイヤーの音量を変化させた場合でも、レギュレータICにより電流に変化がみられなかったため、得られるセンサデータはある程度シンプルとなっていた。しかし、すべての電化製品において同様の挙動を示すとは限らないため、より多くの電化製品で検証を行う必要がある。

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] Beckmann, C., Consolvo, S. and LaMarca, A.: Some assembly required: Supporting end-user sensor installation in domestic ubiquitous computing environments, *UbiComp 2004*, pp.107–124 (2004).
- [3] 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).
- [4] 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).
- [5] 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).
- [6] 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).
- [7] Lukowicz, P., Junker, H., Stager, M., Buren, T.V. and Tröster, G.: WearNET: A distributed multi-sensor system for context aware wearables, *UbiComp 2002*, pp.361–370 (2002).
- [8] 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).
- [9] 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).
- [10] Maekawa, T. and Watanabe, S.: Unsupervised Activity Recognition with User's Physical Characteristics Data, *Int'l Symp. on Wearable Computers*, pp.89–96 (2011).
- [11] 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).
- [12] Philipose, M., Fishkin, K. and Perkowski, M.: Inferring activities from interactions with objects, *IEEE Pervasive Computing*, Vol.3, No.4, pp.50-57 (2004).
- [13] Rabiner, L.: A tutorial on hidden Markov models and selected applications in speech recognition, *Proc. IEEE*, Vol.77, No.2, pp.257-286 (1989).
- [14] Tapia, E., Intille, S. and Larson, K.: Portable wireless sensors for object usage sensing in the home: Challenges and practicalities, *European Conference on Ambient Intelligence 2007*, pp.19-37 (2007).



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。平成 25 年 8~10 月スイス連邦工科大学ローザンヌ校招聘教授。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, 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 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。