

sBike：参加型センシングを志向した モバイルセンシングによる 自転車走行状態収集・共有機構

斉藤 裕樹^{1,a)} 菅生 啓示^{2,†1} 間 博人¹
テープウィロージャナポン ニワット³ 戸辺 義人^{1,4}

受付日 2011年5月30日, 採録日 2011年11月7日

概要：複数のセンサを搭載したスマートフォンに代表される携帯端末が急速に普及している。これにともない、携帯端末を利用して、広範囲にわたる情報をさまざまな人から収集する参加型センシング (Participatory Sensing) が注目されている。参加型センシングの一手法として、自転車に取り付けたセンサにより走行コンテキスト情報を収集する試みが行われているが、これまでの事例では特殊な自転車やセンサを必要とするため適用範囲が限られてきた。本論文では、一般の自転車にスマートフォンを据え付けることで容易に実現可能な自転車走行情報収集・共有機構 sBike (Sensorized Bike) を提案する。sBike では、スマートフォンに搭載されている複数のセンサから走行情報を収集し、走行情報を統計的認識手法を用いて解析することで走行状態の認識を行う。また、sBike のプロトタイプの実装および走行状態認識に関する評価について述べる。

キーワード：ユビキタスコンピューティング, センサネットワーク, モバイルセンシング, 参加型センシング

sBike: Acquisition of Person's State Riding a Bicycle with Mobile Sensing for Participatory Sensing

HIROKI SAITO^{1,a)} KEIJI SUGO^{2,†1} HIROTO AIDA¹
NIWAT THEPVILOJANAPONG³ YOSHITO TOBE^{1,4}

Received: May 30, 2011, Accepted: November 7, 2011

Abstract: Participatory sensing, which uses smart phone and gather information from community is draw attention as rapid spread of smart phone mounted multiple sensor. For example of participatory sensing, studies which gather information through sensor installed at bicycle were conducted. But many studies uses special sensors and it is barrier for widespread participation. In this research, we installed a smart phone on bicycle and build system named Sensorized Bike (sBike). It enables various users to participate participatory sensing easily. Proposed system uses Andoroid mobile terminal and gather sensor datas. Analysis of gathered data uses Hidden Markov Model (HMM) and recognize driving condition. In this paper through design and prototyping of sBike, we evaluated proposed driving condition recognition methods.

Keywords: ubiquitous computing, sensor networks, mobile sensing, participatory sensing

¹ 東京電機大学未来科学部情報メディア学科
Department of Information Systems and Multimedia Design,
Tokyo Denki University, Chiyoda, Tokyo 101-8457, Japan
² 東京電機大学大学院未来科学研究科情報メディア学専攻
Graduate School of Science and Technology for Future Life,
Tokyo Denki University, Chiyoda, Tokyo 101-8457, Japan
³ 三重大学工学部情報工学科
Department of Information Engineering, Mie University,
Tsu, Mie 514-8507, Japan
⁴ 独立行政法人科学技術振興機構 CREST
Japan Science and Technology Agency CREST, Chiyoda,
Tokyo 102-0075, Japan

1. はじめに

無線通信技術および半導体技術の発展にともなうセンサの小型化、低価格化により、さまざまな空間で無線通信機能を有するセンサデバイスが大量に利用できるようになりつつある。近年、加速度センサ、地磁気センサ、GPS 受

^{†1} 現在、株式会社テブコシステムズ
Presently with TEPCO Systems Corporation
a) hsaito@im.dendai.ac.jp

信機など複数のセンサが搭載されたスマートフォンに代表される携帯端末を利用した、Participatory Sensing [2] や、People-Centric Sensing [3], [10] と呼ばれるユーザ参加型のセンシング手法が注目されている。ユーザ参加型センシングでは、ユーザの携帯端末を持ち歩いて周囲の状況をセンシングすることで情報を収集する。ユーザ参加型センシングにより、特定の空間の情報を特定のセンサにより収集するのではなく、携帯端末をユーザが持ち歩くことで広範囲の情報を複数ユーザの複数センサから収集することが可能となっている。すでに、騒音モニタリング [12]、道路モニタリング [13]、ソーシャルネットワークワーキングへの応用 [14] などの分野で研究が進められている。

ユーザ参加型センシングでは、従来のセンサネットワークでの実世界センシングとは、データの収集法だけでなく、収集されるデータの質も異なっている。ユーザが生活の中で収集したデータは、センサのばらつき、収集範囲の偏りやユーザ自身の行動の計測値への影響など、従来のセンサネットワークと比較して定量的な面で精度が低い。このため、生のセンサデータを分析して有意な情報を抽出することが必要となる。また、ユーザ参加型センシングを幅広く普及させるためには、ユーザの参加動機を考慮したシステムを構築する必要がある。このためには、協調作業を考慮した環境や、共通の目的を達成する感覚を共有するような仕組みが求められる。さらに、誰もがセンシングに加われるように一般的な携帯端末に適用可能なシステムが必要となる。

環境保全や健康増進、レクリエーションといった観点から自転車利用者は増加傾向にある。わが国の自転車保有台数は年々増加しており、平成 20 年には約 7,000 万台にのぼった [24]。都市部では特に自転車保有台数が多く、人口あたり 6 割以上の人々が自転車を保有している。また、2002 年に内閣府が発表した地球温暖化対策推進大綱 [23] でも自転車の利用が促されている。自転車が走行可能な道路には歩行者や多くの障害物が存在するため、自転車利用者は障害物を回避しながらの走行を余儀なくされ、事故などの危険性が高まることもある。現在、自治体などにおいて自転車走行に適した安全な道路や観光に推奨される経路を示した地図を作成する試みが行われている [25], [26], [27]。しかしながら、自転車走行に適した状況を調査し個別に地図を作成する手法では、多くの労力を要するため規模や適用範囲に限られる。そこで、本研究では、参加型センシングの特長に注目し、利用者からのセンシング情報を収集することで自転車の走行容易性を示す指標を広範囲かつ容易に集約し共有する仕組みの検討を行う。このためには、利用者の自転車の走行状態を認識し集約することが求められる。走行状態の集約により、多くの利用者が障害物回避などのハンドル操作や急停車を繰り返し行っている自転車走行に適さない道路や、直進走行を多くの利用者が行ってい

る自転車走行に適した道路といった街の状況を見出すことが可能となる。

本研究では、自転車に Android 端末を搭載し、ユーザ参加型センシングを適用することで、誰にでも容易にセンシングへ参加可能な自転車情報収集認識機構 sBike (Sensorized Bike) を提案する。sBike を用いて、走行時のセンシング情報を収集し解析することで、障害物を回避したときのハンドル操作や坂道、路面状態といった走行状態を認識する。認識した情報を自転車利用者が共有することで、自転車の快適性と安全性に関する情報の獲得・共有・検索を可能とする。このようなユーザ参加型センシングにより、近年期待されている環境保全や健康増進といった自転車利用の動機付けを図る。

自転车上に搭載したセンサから得られる生データは、自転車個別の特徴や、運転するユーザごとの特徴によってばらつきが大きく、また、センシングデータを単純に時系列に並べただけでは有効な走行情報を得るのは困難である。そこで、本研究では、生データから走行状態を認識するために確率モデルに基づく統計的認識手法を適用する。具体的には、自転車に備えた地磁気センサ、加速度センサ、GPS 受信機から得られたデータに対し、Hidden Markov Model (HMM) を適用し、自転車の基本的な操作状態の認識を行う。本論文では、さらに、携帯端末に備わる無線通信機能を用いて走行状態の集約・共有を行うシステムのアーキテクチャについて述べる。また、実際の自転车上にプロトタイプを作成することで行った、走行状態認識の評価実験の結果についても述べる。

本論文の構成は以下のとおりである。まず 2 章で、ユーザ参加型センシングにおける自転車走行状態の収集と共有における要件を示し、システムの設計について述べる。3 章では、確率モデルに基づく統計的認識手法によりセンシングデータから走行状態を認識する手法について述べる。4 章では、プロトタイプの実装と評価実験について述べる。さらに、5 章で関連研究について述べ、6 章で結論および今後の課題を述べ本論文をまとめる。

2. sBike の設計

2.1 設計方針

本章では、自転車の走行情報収集機構 sBike の設計方針について述べる。sBike は自転車走行情報の収集上と共有上の課題を解決するため、以下の 3 つの項目を設計方針とする。

情報収集範囲と収集量 従来のセンサネットワークでは、広範囲にセンサを設置するためのコストの制約から空間すべてを網羅することが困難である。そこで sBike では、自転車を用いた参加型センシングを実現し、特殊なセンサや自転車を用いることなく、空間に設置された多数のセンサによらずに、広範囲にわたる走行情

報の収集を目指す。

センシングへの参加の容易さ 自転車走行における情報共有を実現するためには、誰でも容易にセンシングに参加可能なセンサやデバイスを用いなければならない。既存の自転車を用いたセンシングに関する研究では、自転車に複数のセンサを取り付けて情報を収集しているものが多く、特殊な自転車または自転車に搭載した特殊なセンサを用いている。これらの特殊なセンサや自転車から走行状態を計測することは可能であるが、対象が特定のユーザーに限定される。そこで sBike では、特殊なセンサや特殊な自転車を使用することなくセンシングに参加できる走行情報収集システムを目指す。

情報共有に適したコンテキストの抽出 複数のセンシング参加者から集められた大量のセンシングデータから、ユーザーに有効な情報を抽出することは容易ではない。また、加速度や地磁気センサによって計測されるセンシングデータを収集し単に時系列に並べただけでは、有用な走行情報とはならない。本研究の目的は、センシングデータからユーザーが走行中にどのような運転操作を行ったかを認識することである。多くのユーザーの運転操作と地理位置情報を集約することにより、自転車走行における道路状況を把握することが可能となる。sBike では、走行状態を認識した結果とその位置情報を、Web アプリケーション上に地図とともに集約する。この情報を共有し、自転車で走行する際にユーザーが参照することにより、どの道路が障害物が少なく快適かといった街なかの状況を知ることが可能となる。

2.2 システムモデル

sBike では、ユーザー参加型センシングを自転車に適用し、誰にでも容易にセンシングへ参加可能な走行情報収集・共有機構を構築する。そのため、一般に普及している Android 端末をセンシングに用いる。sBike のシステムモデルを図 1 に示す。端末を自転車のハンドル部分に搭載

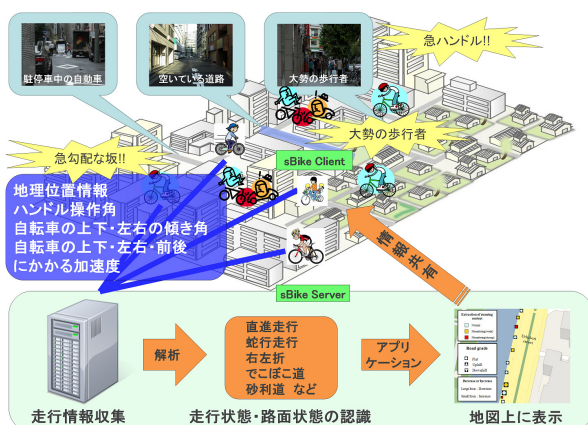


図 1 sBike のシステムモデル
Fig. 1 System model of sBike.

し、3 軸地磁気センサと 3 軸加速度センサ、GPS 受信機から走行情報を取得する。

特殊な自転車やセンサを使用せず、一般に普及している Android 端末を用いることで、誰でも簡単にセンシングに参加することが可能である。センシングに使用する端末は 1 台のみとすることから、大勢の利用者から広範囲の走行情報を収集することが可能である。

また、sBike では、端末の無線通信機能を用いてセンシングデータを即座にサーバにアップロードすることが可能な設計とする。しかし、ネットワークエリア外など通信インフラが存在しない場合においては、端末内に走行情報を保存し、ネットワークエリア内に入ったときにサーバに送信する。端末内に保存された走行情報を、いったん自転車から取り外して PC を通じてサーバに送ることも可能とする。

このようにして複数の sBike 利用者から集められた走行情報はサーバに蓄積される。大量に蓄積された走行情報の中から自転車利用者が快適性や安全性を向上させるために必要な価値ある情報を直接抽出することは困難である。そこで、走行情報を自転車利用者が直観的に理解しやすいコンテキストに変換する。sBike では、走行情報を解析し、自転車の走行状態と自転車が走行した道の路面状態をコンテキストとして抽出する。走行状態を判別するうえで重要な運転操作は自転車の方向を変化させるハンドル操作である。ハンドル操作が求められる運転のうち街なかの状況の判別には、向かう方向は一定で障害物を回避するなどの蛇行走行と、向かう方向自体を変える右左折走行を判別することが最も重要であると考えられる。そこで、本研究では研究の初期段階として、基本的な走行状態である直進、停止とさらに、蛇行走行と右左折走行を加えた 4 状態を認識することを目標とする。そして、これらの状態や運動量を Web アプリケーションや地図上で表示させ、情報共有を実現する。

2.3 アーキテクチャ

sBike は自転車に Android 端末を搭載し、走行情報を収集する sBike_Client と複数の自転車から集められた情報を蓄積し管理する sBike_Server から構成される。システムアーキテクチャを図 2 に示す。

まず、クライアント端末である sBike_Client では、端末固有 ID と 3 軸地磁気センサ、3 軸加速度センサ、GPS 受信機からセンサデータを取得し、Client_AccessControl に送信する。Client_AccessControl では、サンプリングレートに基づきセンサデータのフロー制御を行う。サンプリングレート間隔で取得されたセンサデータに時刻を付与し、これを走行情報とする。次に、走行情報は Client_DataControl へ送信される。走行情報は Client_DataControl を通じてテキスト形式に変換しクライアント内に保存される。即時性の高い情報が必要な場合は走行情報をクライアント内に蓄

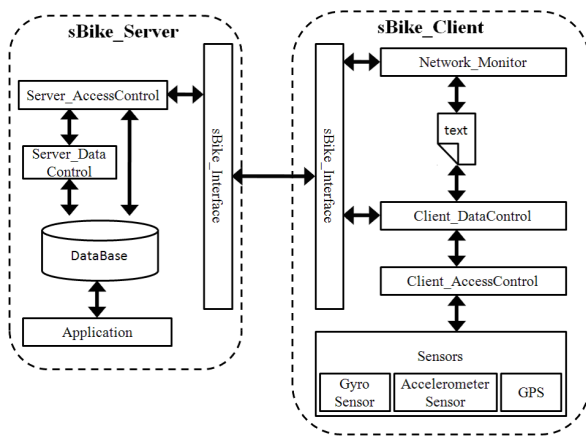


図 2 システムアーキテクチャ
Fig. 2 System architecture.

積するとともに、sBike.Interfaceを通じてsBike.Serveへ走行情報が送信される。また、Network_Monitorでは、現在走行している地点のネットワーク状況をつねに監視している。そのため、通信可能圏外から圏内に移動した場合、クライアント内に保存していた走行情報をsBike_Serverへ送信することを可能とする。

次に、情報を集約するサーバであるsBike.Serverでは、さまざまなセンシング参加者から送信された走行情報をsBike.Interfaceを通じて受信する。sBike.Interfaceでは、走行情報の取得された順に逐次Server_AccessControlへ送信する。Server_AccessControlへ送信された走行情報はデータベースに記録される。また、走行情報はServer_AccessControlを通じてServer_DataControlへ送られる。Server_DataControlへ送られた走行情報は解析され、走行状態や路面状態が抽出される。これらの情報は再度データベースに記録され情報共有に用いられる。

2.4 走行情報の取得

本研究では、自転車のハンドル部分に取り付けたAndroid端末から取得したセンサデータをサンプリングレートに基づき計測し、その値に端末固有のIDと時刻を付与したデータを走行情報と定義する。端末の3軸地磁気センサからYaw(ヨーイング角)、Pitch(ピッチ角)、Roll(ローリング角)を取得し、3軸加速度センサからX軸加速度、Y軸加速度、Z軸加速度、GPS受信機から緯度、経度、高度を取得する。表1に走行情報のメッセージフォーマットを示す。3軸地磁気センサでは、Yawは自転車のハンドル操作角、Pitchは自転車の前後の傾き角、Rollは自転車の左右の傾き角をそれぞれ計測することとなり。3軸加速度センサのX軸は自転車の左右に働く加速度、Y軸は自転車の上下に働く加速度、Z軸は自転車の前後に働く加速度をそれぞれ計測することとなる。

表 1 走行情報のパケットフォーマット

Table 1 Packet format of driving information.

計測値	タイプ	サイズ (byte)
ID	string	64
Yaw	double precision	16
Pitch	double precision	16
Roll	double precision	16
Xaxis	double precision	16
Yaxis	double precision	16
Zaxis	double precision	16
緯度	double precision	16
経度	double precision	16
高度	double precision	16
Time	timestamp	16

3. 走行状態の認識

センサから得られる走行情報は、地磁気センサや加速度センサの計測値であるため、大量のデータからユーザに有効な情報を抽出する必要がある。このため、収集した計測値を解析し、走行状態を抽出する。本研究では、走行情報にHidden Markov Model (HMM)を適用し、自転車の基本的な操作状態である停止状態、直進走行状態、蛇行走行状態、右左折走行状態の4状態を認識する。

3.1 HMMを用いた走行状態の認識

従来、HMMは音声認識の分野などで広く利用されてきた。近年、加速度センサなどのセンサが小型化され、高性能なセンサが安価で入手可能となり、行動認識の分野でも多く活用されている[15], [16], [17], [19], [21]。本研究では、Android端末で収集した走行情報にHMMを適用し走行状態の認識を行う。HMMは、出力シンボルによって一意に状態遷移先が決まらないという意味での非決定状態オートマトンとして定義される。このモデルでは、状態と出力シンボルの2過程を考え、状態が確率的に遷移するときに対応して確率的にシンボルを出力する。各カテゴリのHMMに対して入力パターンの特徴パラメータ時系列に対する尤度を求め、それを最大にするモデルに対応するカテゴリを認識結果とする。HMMは以下の組から定義される。

- 状態の有限集合: $S = s_i$
- 出力シンボルの集合: $O = o_i$
- 状態遷移確率の集合: $A = a_{ij}$ (a_{ij} は状態 s_i から状態 s_j への遷移確率 $\sum_j a_{ij} = 1$)
- 出力確率の集合: $B = b_{ij}(k)$ ($b_i(k)$ は状態 s_i においてシンボル k を出力する確率)
- 初期状態確率: π (π は初期状態が s_i である確率 $\sum_j \pi_j = 1$)

また、HMMにはスペクトルパターンの表現方法により分類されている。本研究では連続分布型HMMを用い

る。連続分布型のシンボル出力 $b_{ij}(o_t)$ は次のように計算される。

$$b_{ij}(o_t) = \sum_{m=1}^{M_{ij}} C_{ijm} N(o_t; \mu_{ijm}, \Sigma_{ijm}) \quad (1)$$

M_{ij} : 状態 i から状態 j の遷移における混合数

C_{ijm} : 状態 i から状態 j の遷移における混合数 m のときの重み

$N(; \mu, \Sigma)$: 平均ベクトル μ , 共分散行列 Σ を持つ混合ガウス分布

また, $N(; \mu, \Sigma)$ は以下の式で表される。

$$N(O; \mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^n |\Sigma|}} \exp\left(-\frac{1}{2}(O - \mu)^t \Sigma^{-1} (O - \mu)\right) \quad (2)$$

n : 観測行列の次元数

$(O - \mu)^t$: $(O - \mu)$ の転置行列

HMM には, あらゆる状態からすべての状態に遷移できる全遷移型モデルや状態遷移が一定方向に進む left-to-right モデルや right-to-left モデルがある。本研究では, left-to-right モデルを用いる。

HMM では記号系列を生成した状態遷移系列は非観測であるため, 直接, 最尤推定を行うことができない。そのため, 期待値最大アルゴリズムを用いた繰返しアルゴリズムによりパラメータを推定する。本研究では観測系列の生成確率を最大にするモデル λ のパラメータの局所的最適値を求める方法として Baum-Welch アルゴリズムを用いる。Baum-Welch アルゴリズムはまず, HMM の各状態について前向き確率と後向き確率を計算する。時刻 t のとき, 観測系列 o_1, o_2, \dots, o_t を出力し, 状態 j にいる前向き確率 $\alpha_t(j)$ を次のように求めることができる。

$$\alpha_t(j) = \sum_{i=1}^N \alpha_{t-1}(i) a_{ij} b_{ij}(o_t) \quad (3)$$

次に, 時刻 t のとき状態 i にいて, 観測系列 $o_{t+1}, o_{t+2}, \dots, o_T$ を出力する後向き確率 $\beta_t(i)$ を次のように求めることができる。

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_{ij}(o_t) \beta_{t+1}(j) \quad (4)$$

前向き確率と後向き確率を算出後に, モデル λ が観測系列 $O = o_1, o_2, \dots, o_T$ を生成する場合, 時刻 t で状態 i から状態 j に遷移する確率 $x_{it}(i, j)$ を以下のように定義する。

$$\begin{aligned} \xi_t(i, j) &= P(s_{t-1} = i, s_t = j | O, \lambda) \\ &= \frac{\alpha_{t-1}(i) a_{ij} b_{ij}(o_t) \beta_t(j)}{P(O | \lambda)} \quad (1 \leq t \leq T) \end{aligned} \quad (5)$$

ここで, 時刻 t で状態 j にいるシンボル生成過程での確

率 $\gamma_t(j)$ を以下のように定義する。

$$\begin{aligned} \gamma_t(j) &= P(s_t = j | O, \lambda) \\ &= \sum_{i=1}^N \xi_t(i, j) \quad (1 \leq t \leq T) \end{aligned} \quad (6)$$

最後に, $\gamma_t(j)$ と $\xi_t(i, j)$ からモデル λ の再推定 ($\lambda \rightarrow \bar{\lambda}$) を以下のように行う。再推定を再帰的に繰り返すことで局所的最適値を求める。

$$\text{初期状態確率: } \bar{\pi} = \gamma_0(i) = \frac{\alpha_0(i) \beta_0(i)}{P(O | \lambda)} \quad (1 \leq i \leq N) \quad (7)$$

$$\begin{aligned} \text{状態遷移確率: } \bar{a}_{ij} &= \frac{\sum_{t=1}^T \xi_t(i, j)}{\sum_{t=1}^T \gamma_{t-1}(i)} \\ &= \frac{\sum_{t=1}^T \alpha_{t-1}(i) a_{ij} b_{ij}(o_t) \beta_t(j)}{\sum_{t=1}^T \alpha_{t-1}(i) \beta_{t-1}(i)} \end{aligned} \quad (8)$$

$$\begin{aligned} \text{シンボル出力確率: } \bar{b}_{ij}(o_t) &= \frac{\sum_{t \in (o_t = v_k)} \xi_t(i, j)}{\sum_{t=1}^T \xi_t(i, j)} \\ &= \frac{\sum_{t \in (o_t = v_k)} \alpha_{t-1}(i) a_{ij} b_{ij}(o_t) \beta_t(j)}{\sum_{t=1}^T \alpha_{t-1}(i) a_{ij} b_{ij}(o_t) \beta_t(j)} \end{aligned} \quad (9)$$

以上のように求めた結果から Viterbi アルゴリズムを用い, 状態認識を行う。Viterbi アルゴリズムは λ において最適な状態系列 (最短経路) $S = s_1, s_2, \dots, s_T$ と, この経路上での確率を求められる。モデル λ において計測系列 $O = o_1, o_2, \dots, o_T$ に対する最適な状態系列 $S = s_1, s_2, \dots, s_T$ を求めるために, 時刻 t での状態 i に至るまでの最適状態確率 $\delta_t(i)$ を以下のように定義する。

$$\delta_t(i) = \max_{s_1, s_2, \dots, s_{t-1}} p(s_1, s_2, \dots, s_t = i, o_1, o_2, \dots, o_t | \lambda) \quad (10)$$

また, 時刻 $t+1$ における最適状態の確率は下記のように導出できる。

$$\delta_{t+1}(j) = [\max_i \delta_t(i) a_{ij}] \cdot b_{ij}(o_{t+1}) \quad (11)$$

時刻 t , 状態 i において生成確率を最大にする経路 (状態遷移) を Ψ , 最適経路の生成確率 p^* , 最適経路上の最終状態を s_T^* とすると最適経路, およびその生成確率は以下の手順で求めることができる。

$$\text{初期化: } \delta_0 = \pi_i \Psi_0(i) = 0 \quad (1 < i < N) \quad (12)$$

$$\text{繰返し: } \delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij} b_{ij}(o_t)] \quad (13)$$

$$\begin{aligned} \Psi_t &= \arg \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij} b_{ij}] \\ &(1 < t < T), (1 < j < N) \end{aligned} \quad (14)$$

$$\text{最終チェック: } p^* = \max_{1 \leq i \leq N} [\delta_T(i)] \quad (15)$$

$$s_T^* = \arg \max_{1 \leq i \leq N} [\delta_T(i)] \quad (16)$$

$$\begin{aligned} \text{経路トレース: } s_t^* &= \Psi_{t+1}(s_{t+1}^*) \quad (t = T-1, \dots, 1) \\ &(17) \end{aligned}$$

経路トレースで求めた $s_0^*, s_1^*, \dots, s_T^*$ が最適経路となる。以上のアルゴリズムを用い自転車の走行状態の認識を行う。




図 3 走行情報の時分割の問題点

Fig. 3 Problem of dividing driving data into time slots.




図 4 走行情報の分割法

Fig. 4 Dividing method for driving information.

3.2 複数タイムスロットの連続性に注目した多数決アルゴリズム

センシングデータから走行状態を認識するため、時系列に並べた計測値を一定時間間隔に区切ったタイムスロットに対して HMM を適用し結果を算出する。しかしながら、単一のタイムスロットに対して単純に HMM 適用するだけでは、その区切りの前後に存在する走行状態の認識が正しく行えない可能性がある。このことを図 3 を用いて例をあげて説明する。走行情報を 3 秒間隔で区切ったとすると、複数の走行状態が含まれるタイムスロットが存在することとなる。図では開始の 6 秒後から 9 秒後までのタイムスロットには停止と直進の 2 つの走行状態が含まれる。また、12 秒後から 15 秒後までのタイムスロットには直進と蛇行の 2 つの走行状態が含まれる。

そこで、図 4 のように基準となる走行情報とともに、1/2 タイムスロット長分割開始時間を遅らせた走行情報を用意する。基準となる走行情報と遅らせた走行情報を組み合わせることで、走行状態の認識精度を向上させる。以下に、具体的なアルゴリズムについて示す。

まず、基準となる走行情報を時分割する。この走行情報を $RI_{1,0}, RI_{1,1}, RI_{1,2}, \dots, RI_{1,n}$ とする。次に、基準となる走行情報を、1/2 タイムスロット長ぶん後方へ遅らせたものを同様に時分割し、この走行情報を $RI_{2,0}, RI_{2,1}, RI_{2,2}, \dots, RI_{2,(n-1)}$ とする。そして、分割されたタイムスロットに対して HMM による状態認識を行う。 $RI_{1,0}, RI_{1,1}, RI_{1,2}, \dots, RI_{1,n}$ から算出されるそれぞれの走行状態を、 $RS_{1,0}, RS_{1,1}, RS_{1,2}, \dots, RS_{1,n}$ とする。同様に、 $RI_{2,0}, RI_{2,1}, RI_{2,2}, \dots, RI_{2,(n-1)}$ から算出されるそれぞれの走行状態を $RS_{2,0}, RS_{2,1}, RS_{2,2}, \dots, RS_{2,(n-1)}$ とする。これらを用いて算出された走行状態を組み合わせ、図 5 に示すアルゴリズムを用いて最終的な走行状態 S_k を導き出す。こ

Algorithm: Driving state recognition

```

1: while do
2:   if  $RS_{1,k} = RS_{2,k}$  or  $RS_{1,k} = RS_{2,(k+1)}$  then
3:      $S_k \leftarrow RS_{1,k}$ 
4:   else if  $RS_{2,k} = RS_{2,(k+1)}$  then
5:      $S_k \leftarrow RS_{2,k}$ 
6:   else if  $RS_{2,(k+1)} = RS_{1,(k+1)}$  then
7:      $S_k \leftarrow RS_{2,(k+1)}$ 
8:   else if  $RS_{2,(k-1)} = RS_{1,(k-1)}$  then
9:      $S_k \leftarrow RS_{2,(k-1)}$ 
10:  else
11:     $S_k \leftarrow RS_{1,k}$ 
12:  end if
13: end while
    
```

図 5 複数の走行情報を用いた状態認識アルゴリズム

Fig. 5 State recognition algorithm using multiple time slots.

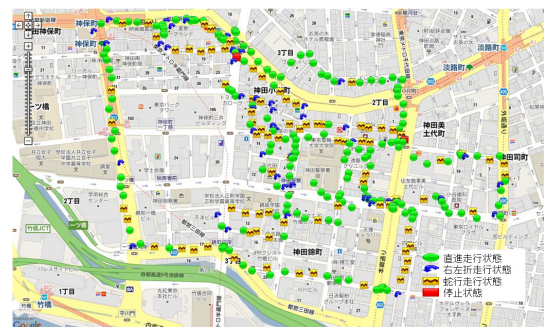


図 6 Web 地図を用いた軌跡表示例

Fig. 6 An example of trajectory using a Web-based map service.

のアルゴリズムでは、隣接する複数のタイムスロットの値の連続性に注目したフィルタリングを行う。具体的には、計測対象のタイムスロット k について、 k と k に隣接する前後のタイムスロットからなる複数の入力に対して連続性に基づいた多数決演算を行い、ノイズを除去した結果として k における認識結果を算出する。

図 6 は、システムで得られた走行状態の軌跡を、Web 地図サービス上に重ねて表示した例である。走行状態を可視化することで、障害物や人ごみによって蛇行走行の多い道路や、停止時間の長い交差点などの情報が得られ、道路や街中の状態を直感的に理解することが容易となる。

4. 評価

本論文で提案する走行状態認識の評価実験を行った。図 7 に示す自転車のハンドルの付け根部分に Android 端末を搭載したプロトタイプにより、端末上に備わるセンサによって走行時のデータを収集した。センサには、3 軸地磁気センサ、3 軸加速度センサ、および GPS センサを用いた。



図 7 Android 端末を装着した sBike のプロトタイプ

Fig. 7 Physical implementation of sBike. Android terminal is installed on the bicycle.




図 8 直進時：地磁気センサ Yaw

Fig. 8 Straight: Yaw on geomagnetic sensor.




図 9 直進時：地磁気センサ Roll

Fig. 9 Straight: Roll on geomagnetic sensor.




図 10 直進時：X 軸加速度

Fig. 10 Straight: X-acceleration.

4.1 学習データ

HMM を用いて走行状態を認識するために、モデルとなる学習データを収集する。そのために、直進走行状態、蛇行走行状態、右左折走行状態、停止状態それぞれの走行情報をあらかじめ収集しておく。それぞれの状態における、3 軸地磁気センサから得られた Yaw と Roll、3 軸加速度センサから得られた X 軸と Z 軸の値を図 8、図 9、図 10、




図 11 直進時：Z 軸加速度

Fig. 11 Straight: Z-acceleration.




図 12 蛇行時：地磁気センサ Yaw

Fig. 12 Meandering: Yaw on geomagnetic sensor.




図 13 蛇行時：地磁気センサ Roll

Fig. 13 Meandering: Roll on geomagnetic sensor.




図 14 蛇行時：X 軸加速度

Fig. 14 Meandering: X-acceleration.

図 11, 図 12, 図 13, 図 14, 図 15, 図 16, 図 17, 図 18, 図 19, 図 20, 図 21, 図 22, 図 23 に示す。

以下、各々の走行状態における計測値の特徴を述べる。なお、2.4 節で述べたように Yaw はハンドル操作角、Roll は左右の傾き角度、X 軸加速度は左右に対する加速度、Z 軸加速度は前後に働く加速度である。蛇行時には、図 12 のように Yaw が大きく上下に変動した後、元の値に戻ることが分かる。図 13 と図 14 に示すように、Roll と X 軸加速度についても、ハンドル操作に対応して変動している




図 15 蛇行時：Z 軸加速度
Fig. 15 Meandering: Z-acceleration.




図 20 停止時：地磁気センサ Yaw
Fig. 20 Stopping: Yaw on geomagnetic sensor.




図 16 左折時：地磁気センサ Yaw
Fig. 16 Left turning: Yaw on geomagnetic sensor.




図 21 停止時：地磁気センサ Roll
Fig. 21 Stopping: Roll on geomagnetic sensor.




図 17 左折時：地磁気センサ Roll
Fig. 17 Left turning: Roll on geomagnetic sensor.




図 22 停止時：X 軸加速度
Fig. 22 Stopping: X-acceleration.




図 18 左折時：X 軸加速度
Fig. 18 Left turning: X-acceleration.




図 23 停止時：Z 軸加速度
Fig. 23 Stopping: Z-acceleration.




図 19 左折時：Z 軸加速度
Fig. 19 Left turning: Z-acceleration.

ことが分かる。これらは、ハンドルを操作した際に、自転車自体が左右方向に移動したことで、操作者がバランスをとるために自転車を傾斜させた際のものと考えられる。また、左折時には、図 16 に示すように Yaw の減少が見られる。これは左折の際のハンドル操作によるものであるが、ハンドル操作と同時に X 軸加速度 (図 18) に増加傾向が見られ、図 19 の Z 軸加速度が、ハンドルの操作中にいったん大きく低下したことが分かる。これらのことから、自転車を傾け減速しながら左折を行ったことが読み取れる。直

進中は、図 8 および図 9 よりハンドル操作と Roll の変動が比較的少ないことが分かる。停止中は、図 20～図 23 よりすべての計測値の変化がきわめて少ないことが分かる。

以上のようにして収集した計測値を学習データとして用い、走行状態の認識を行う。

4.2 実験内容

情報収集と情報共有の実装環境については、走行情報の計測は Sony Ericsson 社の XPERIA SO-01B の上で Java で実装し、走行情報の解析および走行状態の認識は C で記述された Hidden Markov Model Toolkit (HTK) [22] および Java を用いた。また、走行状態の共有のために、Java で実装した GUI と Google Maps API を用いて地図上に走行状態を表示させる Web アプリケーションを開発した。

本実験では、走行状態の認識率に関する評価を行う。実験環境として、図 24 に示すような走行路を用意する。まず、自転車が停止している状態から走行情報の収集を始め、停止状態から直進走行状態に入る。そして、直進走行状態から蛇行走行状態に入り、その後、再び直進走行状態へと戻る。直進走行状態に戻った後に右折または左折を行う。その後は、直進走行状態、蛇行走行状態、直進走行状態、右折または左折を 3 回繰り返す。最後の右折または左折を曲がり終えた後、直進走行状態に入り、その後停止する。この実験を右回りと左回りにそれぞれ 2 回行い、HMM を用い走行状態の認識を行う。実験路の長さは約 450m で、走行時間は停止状態の時間も含めて約 2 分 30 秒である。

効果的な走行状態認識には、HMM を適用するデータの時分割間隔を検討する必要がある。本実験ではまず 1 秒間隔で走行情報を分割した場合と 3 秒間隔で走行状態を分割した場合、それぞれについて認識結果の比較を行う。

4.3 実験結果

実際の走行状態と HMM で認識された走行状態の比較を行った結果、実際の各々の走行状態における正解率は、停止中、直進中、蛇行中、右左折中についてそれぞれ図 25、図 26、図 27、図 28 となった。全体として、3 秒間隔で




図 24 実験環境

Fig. 24 Experiment environment.

分割した場合の走行状態の正解率は 78%，1 秒間隔で分割した場合の正解率は 56.5%であった。1 秒間隔で分割した場合、全体の走行状態に影響しない微細な操作の誤認識が目立つ結果となっている。特に、図 26 の 1 秒間隔での直進走行中の認識結果を分析した結果、バランスをとる際の自然なハンドル操作を右左折や蛇行と誤認識していることが分かった。しかしながら、3 秒間隔で分割した結果においても、特にハンドル操作を必要としない直進走行状態を




図 25 停止中の認識率

Fig. 25 Recognition rate: actual stopping.




図 26 直進中の認識率

Fig. 26 Recognition rate: actual straight forwarding.




図 27 蛇行中の認識率

Fig. 27 Recognition rate: actual meandering.




図 28 右左折中の認識率

Fig. 28 Recognition rate: actual turning.

ハンドル操作が必要である蛇行走行状態と誤認識する割合がまだ高いことが分かる。

次に、3秒間隔で時分割した結果に対し、3.2節で述べた、認識結果の連続性に基づく多数決演算を行った結果を示す。基準となる計測結果と、1.5秒間分割開始時間を遅らせた走行情報を用意し、図5で示したアルゴリズムによって走行状態の認識を行った。得られた走行状態の正解率を、それぞれ図29、図30、図31、図32に示す。直進




図 29 停止中の認識率

Fig. 29 Recognition rate: actual stopping.




図 30 直進中の認識率

Fig. 30 Recognition rate: actual straightforwarding.




図 31 蛇行中の認識率

Fig. 31 Recognition rate: actual meandering.




図 32 右左折中の認識率

Fig. 32 Recognition rate: actual turning.

走行状態の認識率は74%から83%へ向上し、全体の認識率も78%から84%へ向上した。しかしながら、通常のHMMと提案手法を比較すると、蛇行走行中に直進走行と誤認識する割合が0%から11%に、右左折走行中に直進走行と誤認識する率が0%から17%に、それぞれ悪化したことが分かる。この原因の調査を行ったところ、提案手法では次のいずれかの条件が満たされた場合に走行状態を誤認識することが分かった。

- 認識された走行状態の継続時間がタイムスロット長以下の場合
- 認識対象のタイムスロットと1/2前後するタイムスロットの認識結果のうち2つが誤認識であり、誤認識結果が等しい場合

本実験では、このような状況が生じたのは認識を行った全走行状態のうち2.6%であり、そのうち従来のHMMで認識できたものを誤認識したものは1.5%であった。以上から、提案手法は全体的な認識精度を向上させるものであるが、継続時間の短い運転操作が繰り返される際には、時分割を行う時間の設定を通常のHMMよりも短く設定することが、精度の向上に有効であることが分かった。今後は、運転状況に合わせて時分割設定幅を動的に変更する手法を検討し認識率の向上を目指す。

5. 関連研究

本研究を含む人間の行動認識では、センサから得られるデータは時系列情報であるため、時系列パターン認識に適した手法が求められる。時系列パターン認識の手法には、線形予測、ニューラルネットワーク、有限状態機械に基づく離散事象モデルに基づく方法などがあるが、線形予測は表現できるモデルの規模に限界があり複雑な構造を扱うことが困難であり、ニューラルネットワークはパラメータの決定が難しいといった欠点がある。有限状態機械を用いた代表的な手法であるHMMは、アルゴリズムが高速でパラメータの設定が容易であることから時系列パターン認識の分野では実績が多く、音声認識の分野などで広く利用されてきた。近年、加速度センサなどのセンサが小型化され、高性能なセンサが安価で入手可能となり、行動認識の分野でも多く活用されている。人体に装着したセンサから得られるデータを解析する研究には、手書き文字の認識手法[17]のほか、加速度センサの値をHMMで学習させ着席、歩行、起立動作といった動作を認識させる手法[19]や、加速度センサを補うために近距離無線を利用した他ノードとの近隣関係と向きを考慮して精度を上げる手法[16]、ジェスチャ認識のアルゴリズムとしてHMMを改良したparametric HMMの提案[21]などが存在する。また、オフィス環境においてビデオ、音声、コンピュータインタラクションからリアルタイムにユーザの活動状態を認識する際に、HMMを応用した階層型確率推論を用いる手法[15]が提案されて

いる。sBike もこれらの研究と同様に、Android 端末で計測・収集した自転車走行情報にHMMを適用し走行状態の認識を行うものである。

人がセンサとなることで、広範囲にわたる情報を収集する方法である参加型センシングにおいて、最も直接的な実現方法は、人に直接センサを取り付けることである。Human++ [8] や MIThril 2003 [4] では、複数のセンサを人体に取り付けることで人の状態を取得し、コンテキストウェアアプリケーションへの活用が考えられている。また、より安価で簡易な加速度センサを人に持たせることでグループの状態を取得する手法も提案されている [7]。しかしながら、これらの研究はデータの収集に主眼が置かれており、収集したデータから、いかに意味のあるコンテキストを抽出するかについては詳しく述べられていない。これに対し sBike では、自転車を対象とし HMM を用いた走行状態の認識および情報の共有に研究の重点が置かれている。

Delay-Tolerant Networks (DTN) [6] は、長時間ネットワークが切断するような環境下においてデータ転送を実現するためのネットワークプロトコルに関する研究である。DTN をモバイルノードやモバイルセンサに適用し、センサデータを収集する手法の提案として Huggle [18], DFT-MSN [20], Fluid Infrastructure [9] などがある。sBike では、ネットワークに接続できない場合、それぞれの自転車に搭載した Android 端末内に走行情報を保存し、再度ネットワークエリア内に入った際に保存していた走行情報をサーバへと送信する。この機能により長時間ネットワーク切断をする環境下でもデータの収集が可能である。DTN に関する部分は本論文の主眼ではないが、今後はこれらの研究をもとに、より効率的なデータ転送の検討を行う。

自転車にセンサを搭載し、走行状態から周辺状況の収集・共有を行う sBike は、移動ノードにセンサを搭載し、周辺環境のモニタリングやトラッキングを行うモバイルセンシングの一種ととらえることができる。モバイルセンシングの研究には、野生動物のトラッキングなどを対象として移動ノードに GPS や各種センサを載せ周辺環境の情報を収集する ZebraNet [11] や、センサを搭載した複数の小型無人飛行機を飛ばすことで周辺環境のセンシングを行う SensorFlock [1] がある。また、自転車を対象としたモバイルセンシングの研究の 1 つに BikeNet [5] がある。BikeNet では、自転車に複数のセンサを取り付け、速度、移動距離、消費カロリー、道路の傾き、心拍、電気皮膚反応などを取得している。これらの収集した情報は Web ポータルサイトで閲覧し、共有することが可能である。しかしながら、多数のセンサを自転車および運転者に設置する必要があるため、利用者がセンサを意識することなく自転車を利用することは困難である。さらに、自転車に特殊なカスタマイズが施されており日常に利用している自転車をセンシングに使うことが難しい。これらの制約から、BikeNet では適

用範囲と収集できる情報量が限られる。一方 sBike では、特殊な自転車やセンサは必要とせずに、日常使用している Android 携帯と自転車だけを利用するため、誰でも容易にセンシングに参加することが期待できる。

6. おわりに

本論文では、参加型センシングを志向した自転車の走行情報収集・共有機構 sBike を提案した。sBike では、特殊なセンサや自転車を用いることなく、誰にでもセンシングに参加可能とするため、一般に普及している Android 端末を自転車に装着するのみで、走行情報の収集を可能な設計とした。HMM を用いた自転車の走行状態認識手法を提案し、実際の自転車にプロトタイプを作成し認識精度の評価を行った。評価結果から、一般に普及しているデバイスだけで、十分な精度の走行状態の認識が可能であることを示した。また、情報共有の一手法として、地図上での表示や走行状態の可視化について示した。

本研究の応用として、災害時に走行可能な通路やその通路の路面状態といった避難に必要な情報を共有することが考えられる。しかしながら、災害時には平時と大幅に異なる環境を想定しなければならないことや、認識すべき走行状態の要件も異なるため今後の検討課題の 1 つである。また、走行中の速度、路面の状態、ブレーキ操作の有無などの影響を考慮した認識を行うことも今後の課題としてあげられる。センシングデータから複数の要因を分析するためには、主成分分析のような多変量解析手法を適用することが有効であると考えられる。また、本論文では、個人に特化した学習データを用い実験を行ったが、一般に適用可能な汎用性の高い学習データの抽出・生成も今後の課題である。

参考文献

- [1] Allred, J., Hasan, A.B., Panichsakul, S., Pisano, W., Gray, P., Huang, J., Han, R., Lawrence, D. and Mohseni, K.: SensorFlock: An airborne wireless sensor network of micro-air vehicles, *Proc. ACM Sensys 2007*, pp.117-119 (2007).
- [2] Burke, J., Estrin, D., Hansen, M., Parker, A., Ramanathan, N., Reddy, S. and Srivastava, M.B.: Participatory sensing, *Proc. ACM Sensys 2006 Workshop on World Sensor Web (WSW'2006)* (2006).
- [3] Campbell, A.T., Eisenman, S.B., Lane, N.D., Miluzzo, E., Peterson, R.A., Lu, H., Zheng, X., Musolesi, M., Fodor, K. and Ahn, G.: The Rise of People-Centric Sensing, *IEEE Internet Computing*, Vol.12, No.4, pp.12-21 (2008).
- [4] DeVaul, R., Sung, M., Gips, J. and Pentland, A.: MIThril 2003: Applications and Architecture, *Proc. 7th International Symposium on Wearable Computers*, p.4 (2003).
- [5] Eisenman, S.B., Miluzzo, E., Lane, N.D., Peterson, R.A., Ahn, G.-S. and Campbell, A.T.: The BikeNet mobile sensing system for cyclist experience mapping, *Proc. ACM Sensys 2007*, pp.87-101 (2007).

[6] Fall, K.: A delay-tolerant network architecture for challenged internets, *Proc. ACM SIGCOMM 2003*, pp.27-34 (2003).

[7] Feldmeier, E. and Paradiso, J.A.: Giveaway wireless sensors for large-group interaction, *Extended Abstracts on Human Factors in Computing Systems*, pp.1291-1292 (2004).

[8] Gyselinckx, B., Van Hoof, C., Ryckaert, J., Yazicioglu, R.F., Fiorini, P. and Leonov, V.: Human++: Autonomous Wireless Sensors for Body Area Networks, *Proc. Conference on Custom Integrated Circuits 2005*, pp.13-19 (2005).

[9] Kansal, A., Somasundara, A.A., Jea, D.D., Srivastava, M.B. and Estrin, D.: Intelligent Fluid Infrastructure for Embedded Networks, *Proc. 2nd International Conference on Mobile Systems, Applications, and Services*, pp.111-124 (2004).

[10] 木實新一, 瀬崎 薫: 都市生活における実世界センシング, 電気学会誌, Vol.129, No.3, pp.156-159 (2009).

[11] Liu, T., Sadler, C.M., Zhang, P. and Martonosi, M.: Implementing Software on Resource-Constrained Mobile Sensors: Experiences with Impala and ZebraNet, *Proc. 2nd International Conference on Mobile Systems, Applications, and Services (MobiSYS 2004)*, pp.256-269 (2004).

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

[13] Mohan, P., Padmanabhan, V.N. and Ramjee, R.: Nerice: Rich Monitoring of Road and Traffic Conditions using Mobile Smartphones, *Proc. ACM SenSys 2008*, pp.323-336 (2008).

[14] Miluzzo, E., Lane, N.D., Fodor, K., Peterson, R., Lu, H., Musolesi, M., Eisenman, S.B., Zheng, X. and Campbell, A.T.: Sensing meets mobile social networks: The design, implementation and evaluation of the CenceMe application, *Proc. ACM SenSys 2008*, pp.337-350 (2008).

[15] Oliver, N., Horvitz, E. and Garg, A.: Layered representations for human activity recognition, *The 4th IEEE International Conference on Multimodal Interfaces (ICMI 2002)*, pp.3-8 (2002).

[16] Quwaider, M., Plummer, A., Jr., Rao, J., Taghizadeh, M. and Biswas S.: Real-Time Posture Detection using Body Area Sensor Networks, *The 13th IEEE International Symposium on Wearable Computers (ISWC 2009)* (2009).

[17] 嵯峨山茂樹, 中井 満, 下平 博: ストローク HMM に基づくオンライン手書き文字認識方式, 電子情報通信学会技術研究報告, PRMU2000-35, pp.1-8 (2000).

[18] Scott, J., Hui, P., Crowcroft, J. and Diot, C.: Huggle: A Networking Architecture Designed Around Mobile Users, *Proc. 3rd Annual Conference on Wireless On-demand Network Systems and Services*, pp.78-86 (2006).

[19] Takeuchi, S., Tamura, S. and Hayama, S.: Human Action Recognition Using Acceleration Information Based On Hidden Markov Model, *Asia-Pacific Signal and Information Processing Association (APSIPA) Annual Summit and Conference*, pp.829-832 (2009).

[20] Wang, Y. and Wu, H.: Delay/Fault-Tolerant Mobile Sensor Network (DFT-MSN): A New Paradigm for Pervasive Information Gathering, *IEEE Trans. Mobile Computing*, Vol.6, pp.1021-1034 (2007).

[21] Wilson, A.D. and Bobick, A.F.: Parametric hidden Markov models for gesture recognition, *IEEE Trans.*

Pattern Analysis and Machine Intelligence, pp.884-900 (2002).

[22] Hidden Markov Model Toolkit (online), available from <http://htk.eng.cam.ac.uk/> (accessed 2011-05-26).

[23] 地球温暖化対策推進大綱, 環境省地球環境局 (オンライン), 入手先 (<http://www.env.go.jp/earth/ondanka/taiko/all.pdf>) (参照 2011-08-30).

[24] 都道府県別自転車保有台数, 自転車産業協会 (オンライン), 入手先 (http://www.jbpi.or.jp/?sub_id=4&category_id=236&dir_no=TOP_ROOT:236) (参照 2011-08-30).

[25] 神奈川県警察川崎市幸区自転車交通安全マップ (オンライン), 入手先 (www.police.pref.kanagawa.jp/ps/55ps/55pic/55k001-04.pdf) (参照 2011-08-30).

[26] 長野県松本市自転車安全利用マップ (オンライン), 入手先 (<http://www.city.matsumoto.nagano.jp/kurasi/seikatu/jitensya/jitensya/>) (参照 2011-08-30).

[27] 長野県軽井沢町旅の観光マップ (オンライン), 入手先 (<http://kanko.town.karuizawa.nagano.jp/sightseeing/cycling.php>) (参照 2011-08-30).



斉藤 裕樹 (正会員)

1996年明治大学理工学部情報科学科卒業。2001年同大学大学院理工学研究科基礎理工学専攻博士課程修了。博士(工学)。明治大学理工学部助手, 東京電機大学工学部助手を経て, 2005年東京電機大学工学部講師。現在, 同大学未来科学部情報メディア学科講師。オーバレイネットワーク, センサネットワークのソフトウェアの研究に従事。日本ソフトウェア科学会, IEEE, ACM 各会員。



菅生 啓示

1986年生。2009年東京電機大学工学部情報メディア学科卒業。2011年同大学大学院未来科学研究科情報メディア学専攻修士課程修了。同年より株式会社テブコシステムズ勤務, 現在に至る。センサネットワーク, データ解析に関する研究開発を行う。



間 博人 (正会員)

博士(政策・メディア)。東京電機大学未来科学部情報メディア学科プロジェクト助教。IEEE 会員。センサネットワーク, 無線通信, 通信プロトコル等の研究に従事。



テプウィロージャナボン
ニワット

1999年タイ王国チュラロンコーン大学工学部電気工学科卒業。2003年東京大学大学院情報理工学系研究科電子情報学専攻修士課程修了。2006年同博士課程修了。博士(情報理工学)。

同年株式会社KDDI研究所入社。2010年より三重大学工学部助教、現在に至る。ユビキタスコンピューティング、センサネットワークの研究に従事。電子情報通信学会、ACM各会員。



戸辺 義人 (正会員)

1984年東京大学工学部電気工学科卒業。1986年同大学大学院修士課程修了。1992年カーネギーメロン大学Electrical and Computer Engineering修士修了。2000年博士(政策・メディア)。東芝、慶應義塾大学を経て、2002

年東京電機大学助教授。2003年同大学教授。現在、同大学未来科学部情報メディア学科教授。JST CREST研究員。2006年フィンランドVTT客員教授。ユビキタスコンピューティング、センサネットワークの研究に従事。電子情報通信学会、SICE, IEEE, ACM各会員。