

# ライフログ生成のための屋外状況推定手法の検討

田中 剛<sup>1</sup> 鈴木 誠二<sup>1</sup> 土井 千章<sup>2</sup> 中川 智尋<sup>2</sup> 稲村 浩<sup>2</sup> 太田 賢<sup>2</sup> 峰野 博史<sup>1</sup>

**概要:** 近年、モバイルデバイスの高度化によりライフログに関するサービスが注目されている。モバイルデバイスを用いてユーザ毎に高精度なライフログを生成することで、ユーザの位置や状況に応じたコンテキストウェアサービスが創造されていくことが期待される。そこで、本研究ではスマートフォンを用いて屋外におけるユーザの位置や状態だけでなく、停留している場所でのユーザの状況までを推定する手法を検討する。屋外での状況を推定するためにまず、GPS データから位置の分散・速度を算出してユーザの移動・停留判定を行い、停留と判定された場所の情報を取得する。次に、停留している場所でどんな状況であったかを推定するために機械学習を用いてモデルを生成する。モデル生成に必要な説明変数は場所によって変更し、重み付けを行う。説明変数として天気や移動手段、モーションセンサの値などを用いることで、移動・停留判定は約 90%、移動手段推定は徒歩、原付、自動車、電車、新幹線において平均約 83%、居酒屋と大学における状況推定はそれぞれ平均約 85%、90% の推定精度が得られた。

## A Study on Outdoor Situation Estimation method for Lifelog Generation

GO TANAKA<sup>1</sup> SEIJI SUZUKI<sup>1</sup> CHIAKI DOI<sup>2</sup> TOMOHIRO NAKAGAWA<sup>2</sup> HIROSHI INAMURA<sup>2</sup> KEN OHTA<sup>2</sup>  
HIROSHI MINENO<sup>1</sup>

### 1. はじめに

近年、個人の生活行動をデジタルデータとして記録するライフログが注目を集めている [1]。スマートフォンなどのモバイルデバイスの高度化・普及 [2] によるインターネットサービスの向上、GPS (Global Positioning System) や加速度センサなどの小型化した複数のセンサが常に身の回りに存在してきたことから、手軽にライフログを残す環境が充実してきたことが要因として考えられる。我々を取り巻く多種多様で膨大なデータを用いてユーザのコンテキストを推定し、高精度なライフログを生成することで、ユーザの位置や状況に応じたコンテキストウェアサービスの普及が期待されている。筆者らはこれまで、センサハウスにおけるベイジアンネットワークを用いた屋内行動推定、GPS や Google Calendar などのソーシャルデータを用いた屋外行動推定に取り組んできた [3][4]。屋内行動推定で

は住環境のセンサデータを用いて、パソコン利用、外出、掃除、料理、テレビ鑑賞、ゲームをする、就寝、読書の 8 つの具体的な行動を平均約 80% の精度で推定することが可能であるが、屋外行動推定ではスマートフォンの GPS やカレンダー情報を用いて、いつ、どこに訪れたか、という滞在場所までしか推定しておらず、滞在場所での状況など具体的な行動までは推定していない。一方、GPS を搭載したスマートフォンの普及により、多くのユーザが常に個人の位置情報のログデータを残すことが可能となり、位置情報データを様々なデータと組み合わせることで屋外におけるユーザの行動特性やライフスタイルを反映したより具体的な情報を提供できるようになってきた。

そこで本研究では、スマートフォンの GPS を用いて屋外におけるユーザの位置情報を基本的なデータとして蓄積し、蓄積されたデータを分析することで移動状態や滞在場所を推定し、さらに滞在場所での状況まで推定して具体的な行動を含んだライフログを生成する手法を検討する。屋外における状況推定では、ユーザが滞在場所で何をしていたのかという状況を推定することを最終的な目的とした。

<sup>1</sup> 静岡大学大学院情報学研究科  
Graduate School of Informatics, Shizuoka University

<sup>2</sup> 株式会社 NTT ドコモ先進技術研究所  
NTT DOCOMO, Inc. Research Laboratories

推定する状況とは、例えばユーザがショッピングモールに行った時、そこで食事をしていたのか、買い物をしていたのか、映画を観ていたのかなどの複数の状況が考えられる場所での状況を想定している。本手法ではスマートフォンの GPS を用いて移動・停留判定を行い、停留と判定された場所を滞在場所と判断して滞在場所の推定を行う。移動手段や、facebook などの Social Networking Service (SNS) から得られるソーシャルデータなどを用いて、機械学習によって滞在場所での状況を推定する。屋外状況推定手法の精度を評価するため、まずは筆者にとって身近である施設において検証を行った。本手法によって推定精度の高い汎用的な状況推定モデルが生成されれば、より具体的な行動内容を含んだライフログを生成でき、質の高いコンテキストウェアサービスの創造に役立たせることができる。

本論文は、全 5 章で構成される。第 2 章では、関連研究について述べる。第 3 章では、屋外状況推定手法について述べる。第 4 章では、屋外状況推定のための初期実験と状況推定精度の評価について述べる。最後に第 5 章で、結論と今後の課題についてまとめる。

## 2. 関連研究

具体的な行動内容を含む高精度なライフログを生成するためには、ユーザの行動を毎日継続的に記録していかなければならない。行動の記録の手法には主に手動と自動があるが、毎日継続的かつ詳細に情報を記録することを考慮すると、日常生活をごく自然に送るうえでユーザへの負担が比較的軽い自動記録の手法が適している。本章では、屋外行動に関する情報を自動で取得するための既存の取り組みを挙げ、課題をまとめて本研究との差分を明確にする。以降、既存の取り組みを、姿勢に関する行動推定、移動状態に関する行動推定、状態に関する行動推定の 3 つに区分して紹介する。

### 2.1 姿勢に関する行動推定

既存の屋外行動推定に関する取り組みに、姿勢を推定する取り組みがなされている。姿勢とは、歩行、走行、立つ、座るなどのユーザの基礎的な身体動作を指し、ユーザの動作はすべて姿勢をもとに行われる。これまでに組み込まれてきた姿勢の推定の多くは加速度センサを用いて行われ、加速度センサの値から特徴量を抽出することで細かい時間隔で推定が可能である。3 軸加速度センサを用いた姿勢推定 [5] では、加速度センサの値からパワースペクトル、分散、平均などの特徴量を抽出することで歩行、走行、立つ、座るの 4 つの姿勢についてそれぞれ約 97% 以上の推定精度が得られている。

### 2.2 移動状態に関する行動推定

既存の屋外行動推定に関する取り組みに、移動状態を推

定する取り組みがなされている。移動状態とは、歩行、走行、自転車、バスなどのユーザの移動に関する動作を指し、ユーザの行動の中で屋外で多く見られる行動である。これまでに組み込まれてきた移動状態の推定の多くは加速度センサや GPS を用いて行われ、加速度センサの値から特徴量を抽出したり、GPS の位置情報データから移動速度を求めたりすることでユーザの移動時の状態の推定が可能である。携帯電話に搭載された加速度センサ、GPS、マイクを用いた移動状態推定 [6] では、加速度センサの値とマイクの値からパワースペクトル、GPS から時速などの特徴量を抽出することで歩行、走行、自転車、停止、自動車、バス、電車の 7 つの移動状態についてそれぞれ約 80% 以上の推定精度が得られている。

### 2.3 状態に関する行動推定

既存の屋外行動推定に関する取り組みに、状態を推定する取り組みがなされている。状態とは、歩行、走行のほか、階段上る、階段下る、乗車中などの姿勢推定よりも少し具体的な行動も対象とし、移動状態推定よりも抽象度を高めた移動行動全体を指す。これまでに組み込まれてきた状態の推定の多くは加速度センサや GPS を用いて行われ、加速度センサの値から特徴量を抽出したり、GPS の位置情報データから移動速度を求めたりすることでユーザの状態の推定が可能である。携帯端末に搭載された加速度センサ、GPS を用いた状態推定 [7] では、加速度センサの値からベクトル長やベクトルの内積・外積、GPS から速度などの特徴量を抽出することで静止、歩行、走行、乗車中の 4 つの状態についてそれぞれ約 93% 以上の推定精度が得られている。また、人間行動理解のための装着型センサによる大規模データベース構築を目的とした研究団体 HASC (Human Activity Sensing Consortium) [8][9] では、加速度センサの値から分散、平均、標準偏差、エネルギーなどの特徴量を抽出することで静止、歩行、走行、スキップ、階段上る、階段下るの 6 つの状態についてそれぞれ約 52% ~ 90% の推定精度が得られている。

### 2.4 関連研究のまとめ

以上の既存の取り組みについて表 1 にまとめる。既存の屋外行動推定はライフログの生成を目的としておらず、すべてユーザの基礎的な身体動作にのみ焦点が当てられており、具体的な行動内容というものは考慮されていない。スマートフォンの GPS を用いてユーザの移動の軌跡や訪れた場所などを自動記録したり、歩行、走行、自転車の移動状態などを推定して自動記録するサービス [10][11] も存在するが、いずれも滞在場所で何をしていたかまでは推定できず、古い記録を見ただけでは何の目的でその場所を訪れたのかを思い出すことは困難である。

一方、リストバンド型の機器を装着して日々のログを

表 1 既存の屋外行動推定

推定区分	推定対象の行動	使用する情報源 (特徴量)	推定精度
姿勢 [5]	歩行, 走行, 立つ, 座る	・加速度センサ (分散, 平均, パワースペクトル, ベクトル方向, ベクトルの内積)	歩行 97.8%, 走行 96.7%, 立つ 99.7%, 座る 99.7%
移動手段 [6]	歩行, 走行, 自転車, 停止, 自動車, バス, 電車	・加速度センサ (パワースペクトル) ・マイク (パワースペクトル) ・GPS (時速)	歩行 98.1%, 走行 99.9%, 自転車 87.3%, 停止 81.4%, 自動車 88.8%, バス 94.9% 電車 91.8%
状態 [7]	静止, 歩行, 走行, 乗車中	・加速度センサ (ベクトル長, ベクトルの内積, ベクトルの外積, 重力ベクトル) ・GPS (速度)	静止 97.5%, 歩行 99.4%, 走行 92.5%, 乗車中 95.6%
状態 [9]	静止, 歩行, 走行 スキップ, 階段上る, 階段下る	・加速度センサ (分散, 平均, 標準偏差, エネルギー, 相関など)	静止 90.2%, 歩行 52.0%, 走行 75.9%, スキップ 82.1%, 階段上る 61.6%, 階段下る 74.7%

収集してスマートフォンで管理, 分析をすることでヘルスケアやライフスタイルの改善に役立てたりするサービス [12][13] も存在するが, やはり取得できるコンテキストの粒度は粗く, 高精度なライフログ生成という目的では情報量に欠ける. 本研究では, 具体的な行動を含む高精度なライフログの生成を目的としているため, 既存の取り組みでなされている行動推定では情報量不足であり, 自らの具体的な行動を想起することが困難であり, 自分がいつ, どこで, どんな状況で, 何をしていたかという情報は得られない. ユーザの位置や状況に応じたコンテキストウェアサービスを創造するためには, さらに具体的なユーザの行動および状態という情報をログとして記録する必要がある.

### 3. 屋外状況推定手法

いつ, どこで, どんな状況で, 何をしていたかというような具体的な行動内容を含んだライフログを生成するためには, ユーザの屋外での状況を推定する必要がある. 屋外状況推定のアルゴリズムを図 1 に示す. 屋外での状況を推定するためには, まずユーザが滞在している滞在場所の情報が必要となる. そのため, 滞在場所を推定する必要があるが, 滞在場所を推定するためにはユーザが滞在していたという情報を取得しなければならない. そこで, まず①ユーザの移動・停留判定を行い, ユーザが移動しているのか, 停留しているのかというコンテキストを推定する. 移動・停留判定において停留と判定された位置がユーザの滞在場所だと判断できるため, 次に②停留時の位置情報を用いて滞在場所を推定する. 本手法では滞在場所での状況を推定するために機械学習を用いるため, ③機械学習を用いる際に必要となる説明変数を取得する必要がある. 使用する説明変数は滞在場所によって変更し, さらに④滞在場所やユーザによって説明変数の重みを変更することで, ⑤パーソナリティを高めた柔軟な状況推定を行うことが可能となる. 滞在場所での状況まで推定してライフログとして記録することで, 具体的な行動内容を含んだ情報量の多いライフログを生成することができる. 「どこで何をしてい

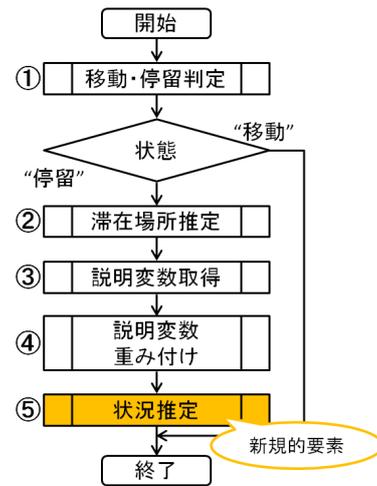


図 1 屋外状況推定アルゴリズム

たのか」という場所と状況まで含んだライフログを生成することで, 後に自身でライフログを確認した時に古い記憶でも鮮明に想起することができるほか, ユーザの位置や状況に応じたコンテキストウェアサービスの創造が可能となる. ライフログの閲覧には, Google Calendar API を用いて, 得られたライフログを 1 つのカレンダーとして生成することでユーザはいつでも, どこでも高精度なライフログを閲覧することができる. Google Calendar はカレンダー毎に表示・非表示の設定ができるため, 普段はライフログカレンダーは非表示にしておき, 閲覧したい時は表示させれば本来のカレンダーとしての機能も損なわず, 専用のアプリケーションなどを開発せずとも簡単にライフログを閲覧することができる. 以降, 屋外状況推定アルゴリズムの各処理の詳細を説明していく.

#### 3.1 移動・停留判定

移動・停留判定では, スマートフォンに搭載された GPS を用いてユーザの移動と停留を判定する. まず, GPS から得られる時刻, 緯度, 経度の値を利用して, ユーザの位置の分散と速度を求める. 速度が速くなった地点は移動と判定でき, 位置の分散が大きくなった地点もそれだけ過去

の地点とのずれが大きいかを指すため移動と判定できる(図2)。逆に、速度が遅い地点、位置の分散が小さい地点は停留と判定できる。速度は、GPSによって前回捕捉された位置から現在の位置までの距離、つまり過去2点分の距離を求め、時刻の差を求めて速度を算出する。位置の分散は、過去5点分のGPSデータを利用し、過去5点分の緯度と経度それぞれの分散を求め、2つの値の二乗和の平方根から1つの値を算出する。位置の分散V (variance) は以下の数式で求められる。nはデータ数(本研究ではn=5)、latは緯度、 $\overline{lat}$ はn個の緯度の平均、lonは経度、 $\overline{lon}$ はn個の経度の平均である。

$$V = \sqrt{\left\{ \frac{1}{n} \sum_{i=1}^n (\overline{lat} - lat_i)^2 \right\} + \left\{ \frac{1}{n} \sum_{i=1}^n (\overline{lon} - lon_i)^2 \right\}}$$

次に、求められた位置の分散と速度の2つを説明変数とし、機械学習によって移動と停留の分類モデルを生成する。本研究では分類モデルを作成する手法として、判定パラメータを明示できる決定木分析による手法を採用する。学習データから移動・停留判定モデルを生成することで、他のデータをモデルに適用すればユーザが今移動しているのか、停留しているのかを判定することが可能となる。

### 3.2 滞在場所推定

滞在場所推定では、移動・停留判定において停留と判定された場所を推定し、その場所の情報を取得する。まず、ユーザがよく訪れる場所はあらかじめデータベース(DB)に緯度と経度を登録しておく。例えば、日常生活を送る上でよく訪れる場所として静岡大学浜松キャンパスが挙げられるならば、「静岡大学浜松キャンパス」という名前、「university」というプレイスタイル(Google Places APIがサポートしているもの[14])とともに静岡大学敷地の北東端および南西端の緯度と経度、つまり2つの対角の緯度と経度の計4つの値をDBに登録する。4つの値を登録することでその場所を矩形範囲で表すことが可能となる。次に、移動・停留判定において停留と判定された場所の緯度と経度が、DBに登録されたいずれかの場所の矩形範囲内にあるかどうかを判定する。もしあらかじめ登録されている矩形範囲内であれば、滞在場所名およびプレイスタイルが容易に取得できる。もし矩形範囲外であれば、Google Places APIを用いて逆ジオコーディングによって近隣の施設名および近隣の施設のプレイスタイルを取得する。

Google Places APIは、緯度・経度を座標として指定することで施設、有名なスポットとして定義されている場所などについての情報をHTTPリクエストを使用して返すサービスである。取得した緯度・経度から周囲100mの範囲にある施設などを検索し、XML形式で出力するためのHTTPリクエストを以下に示す。

<https://maps.googleapis.com/maps/api/place/>



図2 位置の分散による判定イメージ

`search/xml?location=lat,lon&radius=100&types=establishment&language=ja&sensor=true&key=[API_KEY];`

Google Places APIを用いることで、DBに登録されていない場所においても施設名やプレイスタイルを取得することができ、ユーザの滞り場所を推定することが可能となる。

### 3.3 説明変数取得

滞り場所推定によって滞り場所の情報を取得した後に、滞り場所での状況を推定する。滞り場所での状況を推定するために決定木分析による機械学習を用いるため、分析に使用する説明変数を取得する必要がある。本研究では、使用する説明変数として移動手段、趣味や興味・関心などのソーシャルデータ、本研究室で開発した住環境センサノードの各種センサ値を加工したもの、直前の滞り場所での状況などを想定している。使用する説明変数は、ユーザや滞り場所、推定したい状況などによって適宜追加することが可能である。以下に、移動手段の推定、ソーシャルデータの取得、住環境センサノードのセンサ値加工について詳細を述べる。

#### 3.3.1 移動手段推定

滞り場所までの移動手段、滞り場所からの移動手段はその場での目的、つまり状況によって異なることが考えられるため、説明変数の1つとして移動手段が効果的だと考える。例えば学生の居酒屋での状況を考えると、アルバイトのために居酒屋に行く場合はスクーターや自転車、自動車などで居酒屋まで行き、帰りも同じ移動手段で居酒屋をあとにする可能性が高い。しかし飲み会、つまり食事(飲酒)をするために居酒屋に行く場合は居酒屋に行くまでに歩行やバスで行き、帰りは歩行やバス、タクシーなどで帰る可能性が高い。例え行きはスクーターなどで行ったとしても、飲酒をしていれば帰りはスクーターを使うことなく他の移動手段で帰ると考えられる。居酒屋に限らず滞り場所までの、滞り場所からの移動手段によって滞り場所での状況が変わることは大いに考えられるため、移動手段を推定する必要がある。

移動手段推定には、移動・停留判定と同様にGPSデータと決定木分析を用いる。推定の対象とする移動行動および使用する説明変数をそれぞれ表2、表3に示す。推定する移動手段に関する行動は、学生が普段日常生活を送る上

表 2 推定対象行動

歩行, スクーター  
自動車, 電車, 新幹線

表 3 説明変数

Variance(位置の分散: 数値)

Speed(速度: 数値)

Weather(天気: sunny, overcast, rainy)

で比較的多く利用する歩行, スクーター, 自動車, 電車, 新幹線の 5 つの移動手段を対象とする. 使用する説明変数は, 位置の分散と速度のほか, 晴れ, 曇り, 雨などの天気も使用する. 天気を使用する理由は, 雨など天気が優れない場合滞在場所によってはユーザが歩行やスクーターという移動手段を選ばなくなる可能性が高くなることを考慮するためである. 位置の分散, 速度, 天気の 3 つを説明変数とし, 決定木分析によって移動手段推定モデルを生成する. 学習データから移動手段推定モデルを生成することで, 他のデータをモデルに適用すればユーザが移動している最中の移動手段の推定が可能となる.

### 3.3.2 ソーシャルデータ取得

ユーザの趣味や興味・関心, 好きなものなどによって同じ滞在場所でも状況は異なると考えられるため, 説明変数の 1 つとしてソーシャルデータが効果的だと考える. 例えば公園での状況を考えると, ユーザの趣味が散歩ならば滞在場所が公園だと推定された場合公園での状況は散歩中という可能性が高いが, 趣味がサッカーならば公園での状況はサッカーをしている可能性が高くなると考えられる. ユーザ特有のパーソナルな情報をソーシャルデータとして利用することで, 同じ滞在場所での状況推定に役立てられる. そのためには, 説明変数として利用可能なソーシャルデータを取得する必要がある.

ソーシャルデータは, SNS で世界一のユーザ数を誇る facebook から取得する. facebook は国内はもちろん海外でも広く普及しており, プロフィール情報を含め趣味や興味・関心など多くの情報を登録することができるため, ソーシャルデータの取得に最も適した SNS だと言える. facebook API を利用すれば, facebook ユーザのプロフィール情報や投稿など多種多様なソーシャルデータを取得することが可能となる. 取得したソーシャルデータを DB に蓄積しておき, 必要な時に必要なソーシャルデータを取り出し, 説明変数として利用することでよりパーソナリティの高いモデルが生成でき, 状況推定の精度が向上すると考える.

### 3.3.3 住環境センサノードのセンサ値加工

本研究室で開発した住環境センサノードは温度, 湿度, 照度, モーションのセンサが搭載されており, 本ノードを屋外に設置することができれば状況を推定するための有益な住環境データを得ることができる. これまでに我々の研

究室では, 住環境データを用いて在席判定や照明制御に関する取り組み [15][16] も行ってきたため, これらの技術も取り込めば屋内でのユーザの状況というコンテキストも明確に推定できると考えられる. 屋外に設置したセンサの情報を用いて状況を推定するだけでなく, 直前に滞在していた屋内での状況を推定して説明変数として使用することも可能となる. スマートフォンに搭載されたセンサのみならず, 住環境センサノードなどの外部機器からのデータも用いることであらゆるシーンにおいてより汎用的な状況推定が可能となる.

### 3.4 説明変数重み付け

状況推定に使用する説明変数は, 滞在場所, または滞在場所のプレイスタイルによって異なる. 前述の例のように, 居酒屋での状況推定のためには移動手段が効果的だと考えられるが, 公園での状況推定のためには趣味などのソーシャルデータが効果的だと考えられる. また, 公園での状況推定に関しては説明変数とその値がまったく同じだとしてもユーザによっては推定される状況は異なる可能性がある. つまり, 滞在場所のプレイスタイルやユーザによって状況推定に必要な説明変数の重みは異なってくる. そのため, 各プレイスタイル, 各ユーザ毎にそれぞれの説明変数に重み付けする必要がある. 滞在場所やユーザに適したパラメータで機械学習を行わなければならない. 各説明変数に重みを付けて機械学習を行い, 状況推定モデルを生成することでそれぞれのユーザに応じた高精度なライフログの生成が可能であると考えられる.

### 3.5 状況推定

スマートフォンの GPS を用いて移動・停留判定を行い, 停留と判定された位置を滞在場所として滞在場所推定を行う. 滞在場所推定によって得られた情報をもとに, 使用する説明変数を選択して DB から取り出して重み付けを行う. 重み付けを行った説明変数を用いて決定木分析を行い, 状況推定モデルを生成する. 決定木分析に使用する説明変数は滞在場所やそのプレイスタイルによって異なるため, GPS データから算出した位置の分散や速度, 移動手段や天気, ソーシャルデータなど様々な説明変数を用意しておくことで多種多様な場所での状況推定に対応することができるようになる. また, 推定された状況を新たに説明変数として使用することで, より汎用的なモデルを生成することができる.

状況推定モデルを生成することで, どこに行ったという滞在場所情報に留まらず, あらゆるデータを用いることで滞在場所での状況までを推定することが可能となる. 最終的に状況推定をするまでに得られた移動手段や滞在場所の情報と推定した状況などを組み合わせることで, これまでにない情報量豊富なライフログを生成することができる.

## 4. 基礎評価

本章では、第3章で述べた屋外状況推定手法について基礎評価を行う。評価実験は、初期実験として移動・停留判定および移動手段推定の精度評価実験を行う。また、状況推定の精度評価実験として、筆者にとって身近で日常生活を送る上で滞在頻度の高い、居酒屋(筆者のアルバイト先)と大学(静岡大学浜松キャンパス)の2箇所における状況推定を行い、その際の推定精度を評価した。

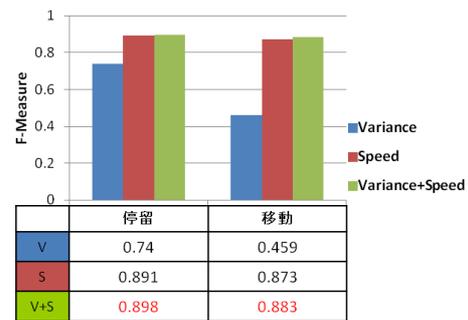


図3 移動・停留判定精度

### 4.1 初期実験

初期実験として、移動・停留判定および移動手段推定の精度評価実験結果および考察を述べる。初期実験では、精度の評価とともにモデル生成に効果的な説明変数を明確にすることを目的とした。実験はともに大学生5名を被験者とし、実験期間は2013年1月28日～2013年2月12日の2週間行った。被験者には、著者らが開発したGPSロガーアプリケーションをインストールしたSamsung製GALAXY S III(Android端末)を所持してもらい、GPSデータとして時刻、緯度、経度の値を収集し続けた。収集した5人のデータから位置の分散と速度を算出し、移動・停留判定および移動手段推定において、使用する説明変数を以下の3つのパターンで決定木分析を行い、精度を比較した。尚、移動手段推定においてはいずれのパターンでも説明変数として天気も使用する。

- (1) 位置の分散(Variance)のみ説明変数とした場合
- (2) 速度(Speed)のみ説明変数とした場合
- (3) 位置の分散と速度を説明変数とした場合

#### 4.1.1 移動・停留判定結果

前述の3つのパターンで決定木分析を行って移動・停留判定モデルを生成し、学習データとは別のテストデータをモデルに適用して得られた結果を図3に示す。学習データは実験期間中のデータからランダムに移動、停留をそれぞれ1,000ずつ取り出し、C4.5にもとづいたJ48アルゴリズムによって移動・停留判定モデルを生成した。テストデータは学習データ以外のデータからランダムに移動、停留をそれぞれ500ずつ取り出し、生成したモデルに適用して精度を評価した。

説明変数に位置の分散のみを用いた場合(1)、停留のF値(F-Measure)は約0.74で移動のF値は約0.46と精度は低かった。停留の再現率(Recall)は1.00という結果が得られているのに対し、移動が停留と誤判定されることから再現率は0.30とかなり低く、それに伴い停留の適合率(Precision)も低くなってしまったことが原因である。屋内で停留している際のGPSの誤差が大きくなる特性から、屋内で停留していたとしてもGPSの誤差によるずれから位置の分散は大きくなってしまふ。そのため、移動・停留判定モデルの位置の分散による閾値が全体的に高めに設定

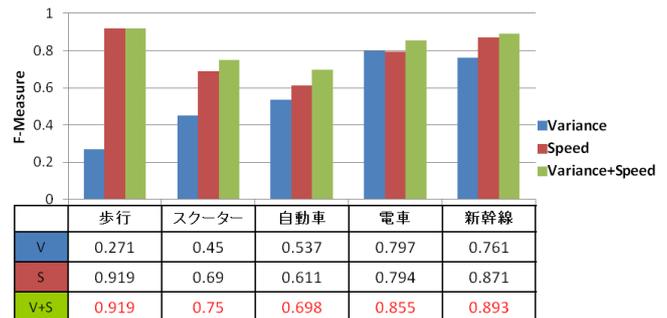


図4 移動手段推定精度

されてしまい、移動していても停留と誤判定されることが多くなったのだと考えられる。一方、説明変数に速度のみを用いた場合(2)と、位置の分散と速度を用いた場合(3)においてはいずれも高い判定精度が得られている。速度のみを用いた場合よりもわずかだが、位置の分散と速度の両方を用いた方が精度は高く、停留のF値は約0.90で移動のF値は約0.88であった。本実験により、移動・停留判定において説明変数として位置の分散と速度が効果的であり、約90%の精度で判定が可能であることが確認できた。

#### 4.1.2 移動手段推定結果

前述の3つのパターンで決定木分析を行って移動手段推定モデルを生成し、学習データとは別のテストデータをモデルに適用して得られた結果を図4に示す。学習データは実験期間中のデータからランダムに歩行、スクーター、自動車、電車、新幹線をそれぞれ150ずつ取り出し、C4.5にもとづいたJ48アルゴリズムによって移動手段推定モデルを生成した。テストデータは学習データ以外のデータからランダムに6つの移動手段をそれぞれ75ずつ取り出し、生成したモデルに適用して精度を評価した。

説明変数に位置の分散のみを用いた場合(1)、移動・停留判定と同様に全体的な精度は低かったが、電車や新幹線などの短時間で大きく位置が変わる乗り物に関してはF値が約0.76以上であり若干の効果が見られた。説明変数に速度のみを用いた場合(2)、歩行や電車、新幹線などの速度に大きな差がある移動手段に関してはいずれもF値が約0.80以上と高い推定精度が得られたが、スクーターと自動車のF値が0.61程度しか得られなかった。この結果

は、自動車は短時間でも信号などによって加速、減速を繰り返す乗り物であり、スクーターと同等の速度で走る状態の頻度が高く、その際のデータがスクーターと誤推定されたことが原因である。そのため、自動車の再現率は約 0.60、スクーターの適合率は約 0.65 と低い精度となっている。一方、説明変数に位置の分散と速度を用いた場合 (3)、それぞれの移動手段に対して F 値が約 0.70 ~ 0.92 と高い推定精度が得られた。この結果は、速度は過去 2 点分の GPS データを用いて算出されることに対して、位置の分散は過去 5 点分の GPS データを用いて算出されることから、位置の分散を説明変数として使用することで乗り物などの移動特性が反映されやすくなったのだと考えられる。本実験により、移動手段推定において説明変数として位置の分散と速度が効果的であり、約 70% ~ 92% の精度で推定が可能であることが確認できた。

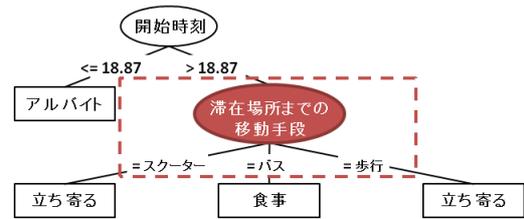


図 5 居酒屋における状況推定モデル

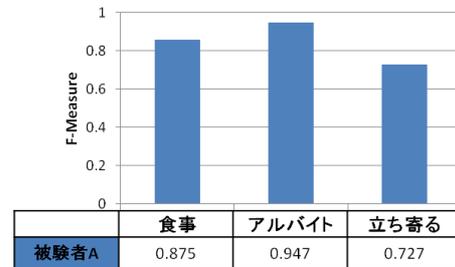


図 6 居酒屋における状況推定精度

#### 4.2 状況推定精度評価実験

状況推定精度評価実験として、居酒屋と大学における状況推定精度評価実験の結果および考察を述べる。状況推定精度評価実験では、同じ滞在場所でも複数考えられる状況をそれぞれ高精度で推定できるか、使用する説明変数は適切かどうかを評価することを目的とした。居酒屋における状況推定は筆者 1 名を被験者とし、大学における状況推定は筆者を含めた大学生 2 名を被験者とした。被験者には、第 4.1 節と同様の端末 (GALAXY S III) を所持してもらい、GPS データとして時刻、緯度、経度の値を収集し続けた。

##### 4.2.1 居酒屋における状況推定結果

居酒屋における状況推定では、飲食店で考えられる状況として食事、アルバイト、立ち寄るの 3 つを推定対象行動とした。決定木分析に使用する説明変数は、開始時刻、終了時刻、曜日、滞在場所までの移動手段、滞在場所からの移動手段、天気を選択した。データ数は食事が 6、アルバイトが 10、立ち寄るが 6 と計 22 しかないため、交差検証法によって状況推定モデルを生成して評価した。生成されたモデルを図 5 に、得られた結果を図 6 に示す。

図 5 より、最初は開始時刻でアルバイトかそれ以外で分類され、次は滞在場所までの移動手段によって状況が分類されるモデルが生成されたことが確認できる。学習データから、スクーターや歩行で居酒屋に行った時は立ち寄るという状況が多く、バスで居酒屋に行った時は食事という状況が多く見られた。このモデルにデータを適用させて得られた結果が図 6 に示した通りだが、食事、アルバイト、立ち寄るの状況において F 値が約 0.73 ~ 0.95 と高い推定精度が得られた。GPS データから移動手段を推定し、その結果を説明変数として決定木分析を行うことで、滞在場所での状況を高精度に推定することが可能であることが確認できた。

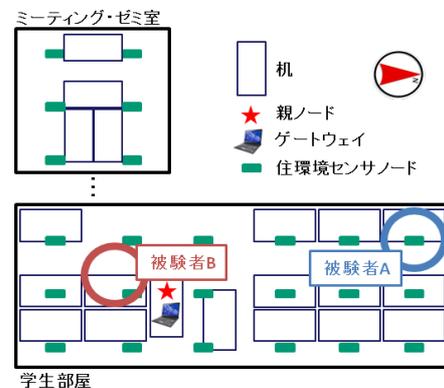


図 7 センサ設置個所および被験者位置

##### 4.2.2 大学における状況推定結果

大学における状況推定では、研究室に配属された学生の主な行動として自席で研究、研究打合せ、全体ゼミの 3 つを推定対象行動とした。決定木分析に使用する説明変数は、研究室内に設置された計 24 個の住環境センサノードそれぞれの 5 分間のモーションセンサ検知回数を用いた。設置されたセンサの位置および 2 名の被験者の自席の位置を図 7 に示す。被験者 A のデータ数は自席で研究が 168、研究打合せが 166、全体ゼミが 118 であり、被験者 B のデータ数はそれぞれ 341、104、20 であり、交差検証法によってそれぞれ状況推定モデルを生成して評価した。得られた結果を図 8 に示す。

図 8 より、2 名の被験者それぞれで F 値が約 0.80 以上と高い推定精度が得られていることが確認できる。自席付近の住環境センサノードの 5 分間のモーション検知回数が多い時は自席で研究している可能性が高くなる。学生部屋に設置された住環境センサノードが全体的にモーション検知回数が少なく、ミーティング・ゼミ室に設置された住環境センサノードが全体的にモーション検知回数が多い時は全体ゼミをしている可能性が高くなる。研究打合せに関し

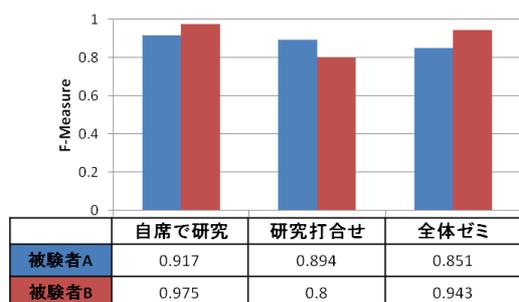


図 8 大学における状況推定精度

ては、自席付近だけでなく同じ研究グループに所属している学生付近の住環境センサノードのモーション検知回数が少なくなり、他の学生の席付近およびミーティング・ゼミ室に設置された住環境センサノードのモーション検知回数が増える。住環境センサノードのモーション検知回数を説明変数として決定木分析を行うことでこれらの特徴が見られ、大学での状況を高精度に推定することが可能であることが確認できた。また、住環境センサの値を説明変数として使用することの有意性が確認でき、今後屋外でも同様のセンサを設置できれば推定できる屋外状況の幅が広がり、より情報量の多いライフログを生成できると考えられる。

## 5. おわりに

本論文では、ユーザの位置や状況に応じたコンテキストウェアサービスの創造の手助けとなる、滞在場所での状況というコンテキストを含んだ高精度なライフログを生成するための屋外状況推定手法について検討した。スマートフォンの GPS を用いて移動・停留判定、移動手段推定を行い、移動・停留判定において停留と判定された位置、つまり滞在場所を推定し、その場所での状況を決定木分析によって推定を行った。評価では、初期実験として移動・停留判定と移動手段推定において位置の分散と速度を説明変数として用いることが効果的だということを確認し、精度は移動・停留判定ではそれぞれ約 90%、移動手段推定では歩行、スクーター、自動車、電車、新幹線において約 70～92% の推定精度が得られた。状況推定では、筆者にとって身近な 2 つの施設において状況を推定し、移動手段を説明変数に使用することで居酒屋での食事、アルバイト、立ち寄るの 3 つの状況を約 73%～95% の精度で推定することができ、住環境センサノードのモーション検知回数を説明変数に使用することで大学での自席で研究、研究打合せ、全体ゼミの 3 つの状況を約 85%～95% の精度で推定することができた。

今後は、状況推定に必要なモデルを効率的に生成するために、日々の生活の中で常に学習し続けられるような仕組みを検討し、ショッピングモールなどの大規模な施設における汎用的な状況推定モデルを生成し、多種多様な状況推定モデルを拡充することでライフログをより詳細化してい

く。また、説明変数の重み付けに関する検討も進めた後に、本手法の妥当性を検証するため、図 1 で示したアルゴリズムの①～⑤の各処理すべてにおいて高い精度を得られるかどうかを評価し、いかなる場所でも本手法が活用できることを確認する。

## 参考文献

- [1] 和田恭, “米国におけるライフログを巡る最近の動向,” 情報処理推進機構, ニューヨークだより 11 月号 (2010).
- [2] Gartner, 世界携帯電話端末 (スマートフォン) 販売台数調査, <http://www.gartner.com/newsroom/id/2237315> (2012.11.14 更新).
- [3] 田中剛, 鈴木誠二, 土井千章, 太田賢, 稲村浩, 水野忠則, 峰野博史, “行動推定を用いた対面コミュニケーション支援システムの提案,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2012) シンポジウム, pp.2359-2366 (2012).
- [4] S. Suzuki, G. Tanaka, C. Doi, T. Nakagawa, H. Inamura, K. Ohta, T. Mizuno, and H. Mineno, “Development of a Topic Providing System with Inferences of Behaviors from Daily Life,” *Journal on Computer Technology and Application*, Vol.4, No.3 (2013) (To appear).
- [5] 倉沢央, 川原主博, 森川博之, 青山友紀, “センサ装着場所を考慮した 3 軸加速度センサを用いた姿勢推定手法,” 2006-UBI-11, pp.15-22 (2006).
- [6] 小林亜令, 岩本健嗣, 西山智, “釈迦: 携帯電話を用いたユーザ移動状態推定方式,” 情報処理学会論文誌 Vol. 50, No.1, pp.193-208 (2009).
- [7] K. Cho, N. Iketani, H. Setoguchi, and M. Hattori, “Human Activity Recognizer for Mobile Devices with Multiple Sensors,” *Symposia and Workshops on Ubiquitous, Autonomic and Trusted Computing 2009*, pp.114-119 (2009).
- [8] HASC (Human Activity Sensing Consortium), <http://hasc.jp/> (2013.05.01 確認).
- [9] 小川延宏, 梶克彦, 河口信夫, “HASC2010corpus を用いた被験者数と人間行動認識率の相関分析,” 情報処理学会マルチメディア, 分散, 協調とモバイル (DICOMO2011) シンポジウム, pp.76-82 (2011).
- [10] 僕の来た道, Yahoo Japan Corp., <http://latlonglab.yahoo.co.jp/service/bokumichi.html> (2013.05.08 確認).
- [11] Moves, ProtoGeo, <http://www.moves-app.com/> (2013.05.08 確認).
- [12] SoftBank HealthCare, Fitbit, Inc., <http://www.softbank.jp/mobile/service/softbankhealthcare/> (2013.05.08 確認).
- [13] UP, JAWBONE, <https://jawbone.com/up> (2013.05.08 確認).
- [14] Google Places API にサポートされるプレイスタイプ, Google Developers, [https://developers.google.com/places/documentation/supported\\_types](https://developers.google.com/places/documentation/supported_types) (2013.05.08 確認).
- [15] 江田政聡, 賀新剛, 中根傑, 横山昌平, 福田直樹, 峰野博史, 石川博, “赤外線センサを用いた在席推定に基づく照明制御手法の提案,” 第 4 回データ工学と情報マネジメントに関するフォーラム (DEIM フォーラム 2012) .
- [16] X. He, T. Mizuno, and H. Mineno, “A Study on a Highly Accurate Appliances Control System Using Wireless Sensor Networks,” *The 1st International Workshop on Smart Technologies for Energy, Information and Communication (IW-STEIC2012)* , pp.43-50 (2012).