

釈迦：携帯電話を用いたユーザ移動状態推定・共有方式

小林 亜令[†] 岩本 健嗣[†] 西山 智[†]

[†]KDDI 研究所 〒356-8502 埼玉県ふじみ野市大原 2-1-15

E-mail: [†]{kobayasi, ta-iwamoto, tomo}@kddilabs.jp

あらまし 本稿では、携帯電話に搭載可能な加速度センサ、マイク、GPS を複合的に用い、ユーザの移動状態を自動的に推定する方式を提案する。従来、走行、歩行、停止といった人間の活動状態に加えて、自転車、電車、バス、自動車といった乗車状態を推定対象とした場合、突発的な振動の変化や、振動が他状態と類似する時間帯が発生することにより、推定精度が低下する課題がある。本方式は、各センサデータの時間的な変化を状態遷移として扱い、各移動状態の推定に適した方式を組み合わせることにより、前記課題の解消を図っている。また、性能評価実験結果により、本方式が、前記 7 状態を概ね 80%以上の精度で推定できることが分かった。さらに、直感的なユーザインタフェースを備えたユーザプレゼンス情報共有方式を提案する。

キーワード 釈迦、移動状態、加速度、GPS、マイク

Shaka: Method for Estimating User Movement Using Mobile Phone

Arei KOBAYASHI[†] Takeshi IWAMOTO[†] and Satoshi NISHIYAMA[†]

[†]KDDI R&D Laboratories Inc. 2-1-15 Ohara, Fujimino-shi, Saitama, 356-8502 Japan

Abstract This paper presents a method for estimating the movement of a user using a system that combines GPS, a microphone and an acceleration sensor able to be fitted in a mobile phone. Past attempts to provide a means to identify movement associated with riding on a bicycle, train, bus or car, in addition to common human movements like standing still, walking or running, have had problems with poor accuracy due to factors such as sudden changes in vibration or times when the vibrations resembled those for other types of movement. The proposed method aims to avoid these problems by treating time-axis changes in the data from each sensor as state transitions, and by combining different techniques for identifying each type of movement. Performance test results show that the method achieves 80% or better accuracy for all seven of the different types of movement mentioned above.

Keyword Shaka, User Movement, acceleration sensor, GPS, microphone

1. はじめに

近年、日本の携帯電話端末は、高機能化が進み、カメラや GPS、RF-ID などのセンサデバイスが搭載され、様々なサービスが提供されている。そして現在、新たな携帯電話サービスとしてコンテキストウェアサービスの検討が進んでいるが、これを実現するには、いかにユーザコンテキストを取得するかが重要な技術的課題の 1 つとなる。

本稿では、ユーザコンテキストのうち、ユーザの移動状態に着目する。ここで移動状態とは、走行、歩行、停止といった人間の活動状態と、自転車、自動車、バス、電車といった交通機関の乗車状態を指している。携帯電話を用いて、これらの状態を自動的に推定することができれば、幅広い適用先が期待できる。

そこで本稿では、携帯電話に搭載可能な、加速度センサ、マイク、GPS の 3 種類のセンサを複合的に用い、ユーザの移動状態を自動的に推定する方式を提案する。本方式は、各移動状態の推定に適した方式を段階的に適用し、推定候補を絞り込むことによって、推定精度向上を図っている。また、各センサデータの時間的な

変化を状態遷移として扱うため、従来の課題であった突発的な振動変化や他状態と類似する時間帯の発生による推定精度低下を回避することが期待できる。

本稿では、まず 2 章で関連研究を紹介し、3 章で要求条件と課題を述べる。次に 4 章で提案方式を述べ、5 章で性能測定実験結果を報告し、6 章で、プレゼンス情報共有方式を提案し、7 章でまとめる。

2. 関連研究

ユーザ移動状態推定方式については、様々な方式が提案されている。Kern ら[1]や、Stephen ら[2]、SenSay[3]、Iso[4]らは、身体の複数箇所に加速度センサ等を装着し、「座る」「立つ」「歩く」「走る」などの動作推定を行っている。これらの研究は、様々なセンサを用いて人間の様々な動作状態を推定可能であるが、センサ装着箇所が複数必要であったり、装着方法が固定化されていたり、現実的でない方式が多い。川原[5]らは、1 つの加速度センサを用い、センサの装着状態を識別し、動作状態を推定する手法を提案しているが、人間の活動状態だけでなく、自転車、自動車、バス、電車といった乗車状態まで含めた移動状態推定方式に関する検討

は、これまで行われていない。

3. 要求条件と課題

3.1. 携帯電話を用いたユーザ移動状態推定方式に対する要求条件

携帯電話を用いたユーザの移動状態推定方式は、以下に列挙する条件が満たされることが望ましい。

条件①：各センサは1つ携帯電話に装着されること

各センサの搭載コストやユーザの装着負担を考慮すると、センサは1つのみ携帯電話に装着されることが望ましい。携帯電話は様々な所持状態を有するため、所持状態に依存しない推定方式が必要である。

条件②：ユーザに依存しないこと

ユーザの負担を考慮すると、ユーザに依存した学習や設定を必要としない方が望ましい。

条件③：完全な自動推定であること

ユーザの負担を考慮すると、ユーザの手動処理を伴わない自動推定方式であることが望ましい。

条件④：状態の遷移を短時間で検知できること

Use Case を考慮すると、移動状態の変化を短時間で検知できることが望ましい。

条件⑤：推定処理負荷が現実的であること

携帯電話の処理性能は限定されているため、推定処理負荷が大きくなってはならない。

3.2. 予備実験

課題を明確化するために、加速度センサ値から得られる1つのパワースペクトルを用いた（加速度値の時間的な変化を考慮しない）場合の推定精度を表1に示す。縦軸は正しい移動状態を示し、横軸は推定結果の移動状態を示す。この手法は、あらかじめ各移動状態を表す代表パワースペクトルと、計測された加速度値から算出したパワースペクトルをパターンマッチングすることにより推定を行っている。FFTを行う際のセンサ値の時間長は2sec(256 サンプル)、各移動状態の代表パワースペクトルは30個としている。

表1から、走行、歩行状態については70%以上の精度で推定可能だが、他状態については推定精度が低いことが分かる（静止状態は、88.6%だが、他状態時に静止状態と誤推定される確率が高い）。これは乗車状態時に、パワースペクトルが時間的に変化し、他状態と類似する時間帯が存在することが要因として考えられる（課題①）。また、デバイスが身体にぶつかるなど、突発的な振動の変化による性能低下も確認されている（課題②）。これらの課題は、パワースペクトルの時間的な変化を考慮して、推定を行うことにより、解消が期待できる。

一方、マイクセンサについては、走行、歩行、停止、自転車など、場所の制約の少ない人間の活動状態の推定は困難であるが、電車、バス、自動車といった環境

雑音に特徴的の差異が見られる状態については、録音データからパワースペクトルを算出し、その時間的な変化に着目すれば、推定が可能と考えられる。

またGPSについては、屋内など測位不可能な環境における推定が困難であり、また数m~100m前後の測位誤差が発生するため、停止、歩行、走行といった低速移動状態の推定は困難であるが、電車のように高速移動であり、特徴的な加減速を行う状態については、定期的な測位結果から平均時速を算出し、その時間的な変化に着目すれば、推定が可能と考えられる。

表1：従来法の推定性能[%]

	走	歩	転	電	バ	車	止
	79.9	10.9	7.3	0.4	0.3	0.2	1.0
歩	0.9	67.6	6.9	5.8	6.5	4.3	8.0
転	0.6	3.2	45.1	10.8	5.8	20.1	14.5
電	0	0.1	0.9	29.6	14.8	11.4	43.3
バ	0	0.2	2.2	28.9	19.1	16.0	33.6
車	0	0.6	4.0	17.7	8.7	27.3	41.8
止	0	0	0.6	4.4	2.8	3.6	88.6

*走：走行，歩：歩行，転：自転車，電：電車
バ：バス，車：自動車，止：停止

4. 提案方式”釈迦”*

本節では、3節で述べた要求条件を満たし、課題を解消することを目的とした方式”釈迦(*)”を提案する。釈迦は、3.1節で述べた要求条件の通り、携帯電話に搭載可能な1つの加速度センサ、マイクセンサ、GPSを用いてユーザの移動状態を推定する方式であり、センサの所持状態に依存せず（条件①）、ユーザに依存せず（条件②）、手動操作を必要としない、完全自動推定方式（条件③）である。また、1回の推定処理負荷を低減し、状態変化を短時間で検知するため、比較的短時間のセンサデータを用いた推定処理を定期的に行う（条件④⑤）。その際に、センサデータの時間的な変化を、状態遷移モデルとして扱うことにより、他状態と類似する時間帯における精度低下の課題（課題①）の解消を図っている。また過去一定時間の推定ログを用いて多数決処理することにより、突発的な振動変化による精度低下の課題（課題②）の解消を図っている。

4.1. 釈迦の処理フロー

釈迦の処理フローの概要を図1に示す。本方式は、まず加速度値から得られるパワースペクトルを用い、

(*)方式名は、中国古典小説“西遊記”の中で、孫悟空が釈迦如来と天界を我が物にできるという賭けを行い、地の果てらしき場所に立つ5本の柱に一筆書き、柱に小便を引っかけ、戻って来たが、実は釈迦の手のひらを周回しただけであったというシーンに起因している。携帯電話に搭載されたセンサを用いて、ユーザのプレゼンス情報を推定し、それを共有することによって、自分に関連する世界の縮図を把握することができる、つまり携帯電話を、釈迦の手のひらのような存在にしたいという思いから本方式を”釈迦”と呼んでいる。

最小誤差推定方式によって推定を行う。その結果が走行、歩行状態であれば、それを推定結果として出力し、終了するが、他状態であった場合には、HMM(Hidden Markov Model)[6]を用いた最尤推定法によって推定を行う。その結果が自転車、停止状態であれば、それを推定結果とし出力し、終了するが、他状態であった場合には、マイクの録音データから得られるパワースペクトルを用い、HMMを用いた最尤推定法によって推定を行う。その結果が自動車状態であれば、それを出力し終了するが、他状態であれば、GPSの測位結果から得られる平均時速を用い、HMMを用いた最尤推定法によって、電車、バス状態の推定を行う。このように、各移動状態の推定に適した複数の推定方式を用い、移動状態を段階的に絞り込むことによって、各移動状態を最小限の処理負荷で、高精度な推定を行うことが可能となる。以下に各々の処理について述べる。

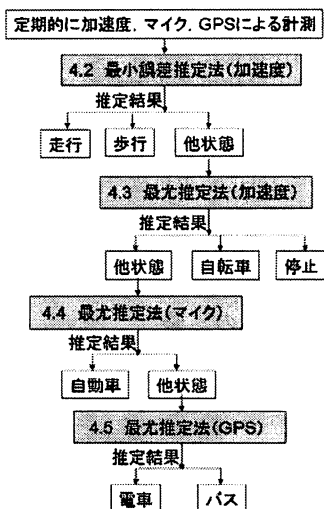


図 1：釈迦の処理フロー概要

4.2. パワースペクトルの最小誤差推定方式

釈迦はまず、加速度値から算出されるパワースペクトルを用いた最小誤差推定法により推定を行う。処理フローを以下に示す。

手順 1：計測された 3 軸加速度値から、2 乗和を算出。

手順 2：2 乗和の時系列データを単位時間毎に分割し、FFT を繰り返し行うことにより、推定用パワースペクトル群を算出する。

手順 3：前記推定用の各パワースペクトルと、あらかじめ移動状態毎に選出した代表パワースペクトル群（選出法は後述）とを、以下の誤差算出式により比較し、最小誤差の P_f が属する移動状態をログ出力する。

$$E_p = \sum_{f=1}^{10} |P_f - p_f|$$

E_p ：1-10Hz の周波数における測定されたパワースペクトルと代表パワースペクトルとの誤差

f ：周波数[Hz], P_f ：代表パワースペクトル

p_f ：推定用のパワースペクトル

手順 4：手順 3 による推定ログを過去一定時間分取得し、その多数決を行い、最高頻度の移動状態を推定結果とする。例えば、直近の推定結果が“自転車”であっても、過去一定時間分の推定ログによる多数決結果が“歩行”であった場合は、推定結果を“歩行”とする。本方式は、加速度値の時間的な変化を状態遷移としては扱っていないが、多数決により突発的な振動変化による精度低下を防ぐことが期待できる。表 1 のとおり、1 つのパワースペクトルでも推定が比較的高精度だった走行、歩行状態については、本方式により十分高精度な推定が期待できる。ただし他状態においては、他状態と類似する時間帯が存在し、本方式による高精度な推定が不可能なため、次節で述べる推定を行う。

なお、代表パワースペクトルは、各移動状態において、代表パワースペクトル選出用の加速度値を計測し、パワースペクトル群を算出した上で、遺伝的アルゴリズム[7]を用いることにより選出を行う。以下に、遺伝的アルゴリズムの各パラメータを示す。

表 2：遺伝的アルゴリズムのパラメータ

パラメータ	設定内容
個体の遺伝子型	代表パワースペクトル (30 個) の組合せ
個体数	100 個
交叉方法	2 つの親個体をランダム選択し、両方の遺伝子群 (延べ 60 個) から、遺伝子 30 個をランダム選択し、子個体とする
評価関数	全パワースペクトルに対する最小誤差の和の逆数
次世代の個体の構成	エリート戦略：30 個 ルーレット戦略：60 個 突然変異：10 個 (突然変異率 10%)
終了条件	50 世代連続無進化、もしくは 300 世代到達

4.3. 加速度センサを用いた HMM 推定方式

4.2 節の方式では推定が困難である移動状態については、HMM を用いた最尤推定法による推定を行う。本方式では、パワースペクトルの時間的な変化を状態遷移モデルとして学習させることにより、確率的な推定を行う。処理フローを図 2 に示す。

学習処理 (図 2 左段) は、まず移動状態毎に HMM 学習用のパワースペクトル群を算出し、4.2 節の最小誤差推定法を用いて、各パワースペクトルを代表パワースペクトルの ID にシンボル化する。生成されたシンボル列 (代表パワースペクトルの ID 列) を用いて、Baum-Welch アルゴリズム [8] による HMM 学習を行い、移動状態毎にモデルを構築する。

推定処理 (図 2 右段) は、まず計測された加速度値から、パワースペクトル群を算出し、各パワースペクトルを代表パワースペクトルの ID にシンボル化する。生成されたシンボル列を用いて、各移動状態のモデルの尤度を算出し、最高尤度のモデルを推定結果とする。また、4.2 節と同様、推定ログの多数決を行い、最高頻度の移動状態を推定結果とする。

本方式は、加速度値の時間的な変化を状態遷移モデルとして表現するため、他状態と類似する時間帯における推定性能低下の回避が期待できる。しかし、電車、バス、自動車状態については、他状態と類似する時間帯が長く、十分高精度な推定が期待できないため、次節で述べる推定を行う。

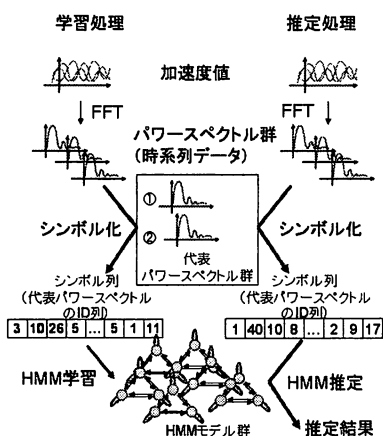


図 2: HMM の学習/推定処理フロー概要

4.4. マイクを用いた HMM 推定方式

前節の加速度センサによる高精度な推定が困難な状態については、マイクデータを用いた最尤推定法により推定を行う。学習処理、推定処理共に前節と同様であるが、以下の通り、シンボル化の処理が異なる。

- (1) 録音データからパワースペクトルを算出する。
- (2) 100Hz~1500Hz までの周波数帯に着目し、100Hz 毎に振幅の平均値を算出する。
- (3) (2)によって生成された振幅の平均値で構成される 14 次元ベクトルと、あらかじめ 4.2 節と同様の方式により選出された代表ベクトルとを比較し、代表ベクトルの ID にシンボル化する。
- (4) (3)を一定時間置きに繰り返し実施することにより、

生成されたシンボル列を用いて、HMM 学習処理や HMM 推定処理を行う。

上記着目周波数帯は、特徴的な振幅を示す周波数帯が 100Hz~1500Hz であることを根拠に設定した。本方式により、加速度センサでは、他状態と類似する時間帯の多かった自動車状態において、マイクデータを用いることにより特徴的な差を見出すことができ、推定精度向上が期待できる。バスと電車状態においても、概ね精度の向上が期待できるが、電車内が混雑している際に、録音される環境雑音の音量が全体的に小さくなり、バス状態に類似するケースが存在し、十分高精度な推定が困難であるため、次節で述べる推定を行う。

4.5. GPS を用いた HMM 推定方式

前節までの方式では推定が困難だった、バスと電車状態については、GPS による測位結果を用いた最尤推定法により推定を行う。バスと電車では平均時速分布が大きく異なることから、GPS 測位誤差が生じた場合でも十分高精度な推定が期待できる。学習処理、推定処理共に前節と同様の手法であるが、シンボル化の処理が異なる。まず GPS 測位を定期的実施し、各 2 点の測位結果から平均時速を算出する。そして、各平均時速に対して 10km/h の単位で量子化を行い、シンボル化する。その結果、生成されたシンボル列を用いて、HMM 学習処理や HMM 推定処理を行う。

5. 性能評価実験

5.1. 評価システムの実装

まず評価実験に使用した端末の写真を図 3 に、スペックを表 3 に示す。




図 3: 端末画像

表 3: センサモジュールスペック

項目	仕様
寸法, 重量	10cm x 5cm x 2cm, 85g
マザーボード	gumstix basix 400xm-bt (CPU:Xscale 400MHz Memory:64MB)
加速度センサ	旭化成製 AK8971N (6 axis,128Hz)
マイク	サンプリングレート: 24KHz 音声フォーマット: PCM(16bit)
GPS	au W44T に内蔵

マイクと GPS は現状既に携帯電話に搭載されており、加速度センサも技術的には携帯電話への搭載が可能である。よって本方式のセンサ構成は、現実的であると言える。また、推定ソフトウェアは、C 言語で実装し、上記端末上 (OS: Linux) で動作させた。本システムに

における各推定方式の動作パラメータを表4に示す。

表4：動作パラメータ

項目	パラメータ
FFT(加速度)の時間窓長	2sec(256サンプル)
時間窓のずらし幅	0.5sec(64サンプル)
多数決(最小誤差法)の推定ログ数	60回(30sec)
HMM(加速度)のシンボル長*推定ログ数	6個*60回(180sec)
FFT(マイク)の時間窓長	300msec(7200サンプル)
時間窓のずらし幅	10sec
HMM(マイク)のシンボル長	18個(180sec)
GPS測位間隔	20sec
HMM(GPS)のシンボル長	9個(180sec)

5.2. 実験データ

本実験では、被験者5名、移動状態7状態(走行、歩行、自転車、電車、バス、自動車、停止)とし、端末の所持状態は、手に所持、端末操作、ズボンのポケット、胸ポケット、カバンの中、の5種類とした(手に所持しながら自転車乗車などの実験困難な3つのケースは行っていない)。電車状態については、車内混雑時と閑散時の2状態を、自動車状態については、窓の開閉、ラジオのON/OFFの4種類の状態におけるデータを用いた。これらのバリエーションに則って合計約40時間分のセンサデータを計測し、半分を学習用、残り半分を推定用データとして用い、性能評価を行った。

5.3. 性能測定結果

まず表5に、加速度値を用いた最小誤差方式(4.2節)の性能評価結果を示す。表1の従来法の推定性能と比較すると、本方式により、大幅に性能向上できているが、走行、歩行以外の状態の推定精度は依然低い。ただし、走行、歩行、他状態の3状態の推定であれば、100%に近い推定精度が得られる。これは、多数決推定方式により、突発的な振動変化による性能低下を回避できていることが要因と考えられ、本方式で高精度な推定が可能な移動状態は走行、歩行状態のみであると言える(停止状態の推定精度は99.8%であるが、他状態時の誤推定の頻度が高いため高精度とは言えない)。

次に、加速度値を用いたHMM推定法の推定精度を表6に示す。表1、5と比較すると、本方式により大幅な性能改善が確認できるが、自転車、停止以外の状態の推定精度に改善の余地が残っている。ただし、自転車、停止、他状態の3状態の推定であれば、90%程度の推定精度が得られる。これは、HMMを用い、パワースペクトルの時間的変化を考慮した推定を行うことにより、パワースペクトルが類似している時間帯による性能低下を回避できていることが要因と考えられ、本方式で高精度な推定が可能な移動状態は自転車、停

止状態のみであると言える。

次に、マイクデータを用いたHMM推定法の推定精度を表7に示す。表6と比較すると、本方式により、自動車、バスについては、100%の精度で推定できる。これは、加速度を用いた推定により、環境雑音に特徴のある自動車、電車、バスの3状態に絞り込まれていることによって、高精度な推定を可能としていると考えられる。その一方、電車状態については、バス状態と誤推定されるケースが多い。これは前述のとおり、電車内が混雑している際に、録音される環境雑音の音量が全体的に小さくなり、バス状態に類似するためと考えられる。よって、本方式で高精度な推定が可能な移動状態は自動車状態のみであるといえる。

次に、GPSの測位結果を用いたHMM推定法の推定精度を表8に示す。表7と比較すると、本方式により、電車、バスの両状態とも90%以上の推定精度が得られていることが分かる。これは、マイク同様、GPSのみでは、7種類の移動状態の推定は困難であるが、加速度、マイクを事前に用い、GPS測位結果に特徴的差異のある電車とバスの2状態まで、推定候補が絞り込まれていることが要因と考えられる。

また表9の釈迦全体の推定精度から、全移動状態を80%以上の精度で推定できていることが分かる。さらに本手法では、走行、歩行状態の推定に1回当たり30秒間、他状態の推定に1回あたり180秒間のセンサデータを用いていることから、状態遷移に対しても15-90秒以内の時間で検知できることが期待できる。さらに、1回当たりの推定処理時間は、実験端末で0.9sec程度であり、十分現実的な処理負荷であると言える。

表5：最小誤差法の推定性能[%]

	走	歩	転	電	バ	車	止
走	99.9	0.1	0.0	0.0	0.0	0.0	0.0
歩	0.0	96.3	0.3	0.2	2.6	0.0	0.4
転	0.0	0.0	76.9	1.1	0.3	17.4	2.1
電	0.0	0.0	0.0	43.6	1.7	1.2	51.4
バ	0.0	0.0	0.0	36.1	9.1	5.4	44.0
車	0.0	0.0	0.0	9.5	0.3	27.0	60.6
止	0.0	0.0	0.0	0.0	0.0	0.1	99.8

表6：加速度値を用いたHMM推定法の推定精度[%]

	自転車	電車	バス	自動車	停止
自転車	88.9	0.0	0.0	11.1	0.0
電車	0.0	59.4	30.7	0.5	9.4
バス	0.0	19.8	71.8	8.3	0.0
自動車	0.0	0.0	32.6	51.5	7.6
停止	0.0	0.0	0.0	6.1	93.8

表7：マイクを用いたHMM推定法の推定精度[%]

	電車	バス	自動車
電車	64.2	35.8	0.0
バス	0.0	100.0	0.0
自動車	0.0	0.0	100.0

表8：GPSを用いたHMM推定法の推定精度[%]

	電車	バス

電車	93.4	6.6
バス	2.1	97.9

表 9： 駅への推定性能[%]

	走	歩	転	電	バ	車	止
走	99.9	0.1	0.0	0.0	0.0	0.0	0.0
歩	0.0	96.3	0.3	0.2	2.6	0.0	0.4
転	0.0	0.0	88.9	0.0	0.0	11.1	0.0
電	0.0	0.0	0.0	84.6	6.0	0.0	9.4
バ	0.0	0.0	0.0	2.1	97.9	0.0	0.0
車	0.0	0.0	0.0	0.0	0.0	92.4	7.6
止	0.0	0.0	0.0	0.0	0.0	6.1	93.8

6. ユーザプレゼンス情報共有方式

前述したユーザの移動状態推定結果を含む、ユーザプレゼンス情報の共有方式を提案する。ユーザプレゼンス情報は、「いつ」「誰が」「どこで」「誰と」「何をしているのか」のパラメータで表現できる。そこで本方式では、これらのパラメータを、表 10 に示す手段で取得し、PIDF(Presence Information Data Format)[9]に準拠したデータに格納し、SIP[10]を用いて共有する。

表 10： ユーザプレゼンス情報の取得手段

プレゼンス種別	取得手段
いつ、誰が	現在(GPS時刻を取得)、端末IDを取得
どこで	GPSにより位置測位を行い、結果をPOI(地点情報)サーバに問い合わせることにより、周辺の地点情報を取得
誰と	同一の基地局ID→GPS測位結果による距離が閾値以下→Bluetoothのディスカバリーでデバイス発見により同行判定
何をしているのか	移動状態については前節の推定結果、端末操作状態は端末イベントから取得

さらに、ユーザが直感的にプレゼンス情報を把握できるように、Augmented Reality (拡張現実感)の概念を持った閲覧手段を用いる。一般的なARでは、図4のように、カメラで撮影した実画像に対して、付随する情報の位置を重ね合わせて表示するが、本方式では視認性を向上させるため、図5のように、液晶ディスプレイ上に実画像を提示せず、関連情報のみを提示する。そして画面に表示すべき関連情報の検索や、画面内の表示位置決定は、6軸センサからyaw(方位),pitch(前後傾き)を取得し、液晶画面が実空間からクリッピングしている緯度経度範囲を算出することにより処理する。また端末姿勢変化に対する追従性向上のため、OpenGL ESによるハードウェアレンダリングを行っている。図6に関連情報提示例を、図7にプレゼンス情報の提示例(例：電車乗車中で、東京ドームの近くにおいて、メールを書いている)を示す。

7. まとめ

本稿では、ユーザの移動状態を自動的に推定する方式を提案し、性能評価実験から、7種類の移動状態を80%以上の精度で推定できることが分かった。また、プレゼンス情報の共有方式を合わせて提案した。今後

は、更なる精度向上や携帯電話における処理負荷計測等を行う予定である。




図 4： 一般的な AR




図 5： 提案方式




図 6： 液晶画面が地表面に対して垂直の場合




図 7： プレゼンス情報

文 献

- [1] Nicky Kern, "A Model for Human Interruptability: Experimental Evaluation and Automatic Estimation from Wearable Sensors," ISWC'04, pp.158-165(2004).
- [2] Stephen S.Intille, "Acquiring In Situ Training Data for Context-Aware Ubiquitous Computing Applications," CHI 2004, ACM Press, pp. 1-9(2004).
- [3] Daniel Siewiorek, "SenSay: A Context-Aware Mobile Phone," ISWC'03(2003).
- [4] Toshiki Iso, "Personal Context Extractor with Multiple Sensor on a Cell Phone," D. 2 C200525(2005).
- [5] Y. Kawahara, "A Context-Aware Content Delivery Service Using Off-the-shelf Sensors," Mobisys2004.
- [6] L.R.Rabiner, "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition", Proc. of The IEEE, pp.257-286 (1989)
- [7] John H. Holland, "Adaptation in Natural and Artificial Systems "(1975).
- [8] L.E.Baum, "Statistical inference for probabilistic functions of finite state Markov chains" The Annals of Mathematical Statistics, vol.37, pp.1554-1563 (1966)
- [9] PIDF: <ftp://ftp.rfc-editor.org/in-notes/rfc3863.txt>
- [10] SIP: <http://tools.ietf.org/html/rfc3261>