

推薦論文

スマートフォンを活用した 屋内環境における混雑センシング

西村 友洋^{1,a)} 樋口 雄大¹ 山口 弘純¹ 東野 輝夫¹

受付日 2014年3月5日, 採録日 2014年9月12日

概要: スマートフォンの普及にともない、歩行者向けのナビゲーションが広く利用されてるようになっていく。日常的に多くの人々が往来する地下街や商業ビルなどにおいて、各地点の混雑状況を把握することができれば、ユーザの状況に応じた移動支援などが可能になり、ナビゲーションシステムの利便性が大幅に向上することが期待される。そこで本論文では、スマートフォンに内蔵されたマイクおよび加速度センサを用いて端末保持者の周囲の雑踏音およびユーザ自身の歩行動作をセンシングすることで、周囲の混雑状況を推定する手法を提案する。一般に混雑時には周囲の群衆の歩行速度に合わせて移動するため、平時と比べて歩行のステップ周期に変化が生じる。また、混雑時は、環境音の低周波成分が増大する傾向がある。提案手法では、これらの知見に基づき、加速度および環境音の測定値から特徴量を抽出し、各ユーザのモバイル端末上でリアルタイムに混雑状況の判定を行う。各端末による判定結果をクラウドサーバ上で共有することで、混雑情報の参加型センシングが実現できる。実環境において性能評価実験を行い、周囲の混雑状況を平均約 70%の精度で認識できることを確認した。

キーワード: モバイルセンシング, 歩行者ナビゲーション, 混雑推定

Low-cost Indoor Crowd Density Sensing with Smartphones

TOMOHIRO NISHIMURA^{1,a)} TAKAMASA HIGUCHI¹ HIROZUMI YAMAGUCHI¹ TERUO HIGASHINO¹

Received: March 5, 2014, Accepted: September 12, 2014

Abstract: Now that smartphones are becoming more and more popular, pedestrian navigation systems are widely used in our daily life. While they usually recommend the shortest distance route to a destination, travel time and ease of walking depend not only on the distance but also on congestion along the path. In this paper, we propose a method for estimating levels of congestion around mobile phone users, aiming to enhance the convenience of such navigation systems. We conducted field experiments and confirmed that this system can achieve reasonable performance.

Keywords: Mobile sensing, pedestrian navigation, crowd density estimation

1. まえがき

スマートフォンの普及にともない、GPS や WiFi 測位などを用いた歩行者向けのナビゲーションサービスが広く利用されるようになっていく。目的地までの最短ルートを案内する従来の基本的なナビゲーションサービスに加えて、

近年では、雨の日や日差しの強い日に地下街など屋根があるルートを優先的に提示したり、大きな荷物を運ぶユーザに対して階段をなるべく避けるようなルートを案内したりするなど、地図情報を最大限に活用することで、ユーザの状況に応じた利便性の高いナビゲーションが実現されている [1]。一方、主要駅周辺の地下街やイベント会場など多

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

a) t-nisimr@ist.osaka-u.ac.jp

本論文の内容は 2013 年 7 月のマルチメディア, 分散, 協調とモバイル (DICOMO2013) シンポジウム 2013 にて報告され, モバイルコンピューティングとユビキタス通信研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である。

くの人々が往来する場所では、目的地までの経路の混み具合によって所要時間が大きく変化する。また、身体的障害をかかえる人々や、乳幼児を同伴し移動に負担がともなう人々に対しては、混雑したエリアを避けるルート案内するなど、より安全な移動方法を提示できることが望ましい。車両向けのナビゲーションシステムにおいては、一般に、VICSなどの路側機や車両プローブ情報から収集される渋滞情報を考慮してルートが決定されているが、歩行者ナビゲーションでは、こうした経路上の混雑状況がルート案内に反映されていないのが現状である。

ショッピングモールや地下街といった公共空間における群衆の動きを高い精度でトラッキングすることを目標として、監視カメラなどの映像を用いた人流推定手法がこれまで数多く提案されている [2], [3], [4]。こうした映像ベースのトラッキング手法を応用すれば、各エリアにおける歩行者の密度の推定が可能になると考えられるが、監視範囲が限られていたり、死角が存在したりするなどの課題も多い。一方で、一定数の協力者の存在を前提としたいわゆる参加型センシングの仕組みを用いて、WiFi 測位などにより得られる位置情報をモバイル端末から集約することで、群衆の存在分布を推定することも考えられるが、そういったアプローチは、非協力者を含めた全体の人数を協力者の絶対数から推定する、ある種の統計的推定であるため、その正しさを保証するためには多数の協力者の存在が必要である。また、協力者の存在情報を収集するだけでは混雑の程度やそれともなう歩きやすさなど、本研究が対象とするような混雑特徴の把握は困難である。また、近隣のモバイル端末間で Bluetooth による無線通信を行い、受信電波強度のばらつきなどをもとに群衆の密度を推定する手法 [5] も提案されているが、同様に歩行流の速度や歩きやすさなどを把握することは難しい。

そこで本研究では、スマートフォンに内蔵された加速度センサおよびマイクを用いて混雑時の雑踏音およびユーザの歩行動作をセンシングすることで、地下街など日常的に多くの人々が往来する環境において、エリアごとの混雑状況をリアルタイムに推定する手法を提案する。一般に、多数の通行人で混雑した通路では、周囲の群衆の流れに合わせて移動を行う必要があるため、歩行時の1歩ごとの時間間隔(ステップ間隔)が平時と比べて増大する傾向がある。また、通路の交差点など複数の人の流れが交わる地点では、異なる方向へ向かう人との衝突を避けるため、歩行時のステップ間隔のばらつきが一時的に大きくなる。さらに、混雑時には、雑踏音や周囲の人の会話音によって、環境音の低周波成分が増大する。本論文では、Android 端末を用いた予備実験を通じて、混雑度推定に有効なセンサ特徴量を明らかにし、それに基づき混雑度の分類アルゴリズムを設計する。環境内のモバイル端末群によるセンシング結果を、WiFi 測位や pedestrian dead reckoning (PDR) に

より推定した端末の位置情報とともにサーバ上へ集約し、複数の端末から得られた情報をエリアごとに統合することで、対象領域全体の混雑状況の把握を実現することを目指している。

提案手法の性能を評価するため、地下鉄御堂筋線梅田駅改札付近の地下街エリアで Android 端末を用いた実証実験を行い、様々な混雑状況の下で、提案手法の混雑度推定精度を評価した。その結果、各被験者の周辺の混雑状況を平均約 70% の正解率で認識できることを確認している。

2. 関連研究

2.1 モバイル端末向け位置推定手法

屋内環境におけるモバイル端末向けの測位技術としては、WiFi アクセスポイントからの電波の受信状況に基づく測位方式 [6], [7] が一般的である。また、加速度センサや電子コンパスといったセンサを用いて歩行者の移動軌跡を推定する PDR 技術も活発に研究されている [8], [9], [10], [11]。

提案手法は特定の測位技術には依存しないものの、WiFi 測位方式では電波伝搬が人体などに影響を受けやすいことから、一般的なシステムでは最大 10m 程度のやや大きい測位誤差を想定しておくべきである。加えて PDR を用いれば、WiFi 測位でカバーできない領域も自律的に補完できるため、本論文では対象とする屋内領域のどの地点でもおおそ 10m 程度で測位可能な環境を想定する。このような環境でも、提案技術が対象とするような商業施設のフロアや地下街通路、駅構内といった領域単位での混雑推定は十分可能であると考えられる。

2.2 移動体トラッキング

環境内に設置されたカメラやセンサ機器を用いて歩行者流のトラッキングを行うための技術も活発に研究されている [2], [3], [4]。こうした映像ベースのトラッキング技術を用いれば、環境内の歩行者の数や移動軌跡を高精度に計測することができるが、1台のカメラで監視可能な領域は限られているため、広いエリアの混雑状況を網羅的に把握するためには、多数のカメラを設置する必要がある。また、プライバシーの観点から、カメラの設置や映像の利用が制限される場合もある。

Laser Range Scanner (LRS) を用いた人流計測手法も数多く提案されている。LRS は、レーザ光の伝搬遅延時間を利用して、半径数十 m 以内にある物体までの距離を正確に計測することができる。たとえば、文献 [12] では歩行者の足首付近を LRS を使って計測し、計測した足首の移動パターンから二足歩行の歩行リズムを検出して歩行者トラッキングを行っているが、歩行者の密度が高い環境では、センサの近くを通行する歩行者や障害物によってレンジセンサの視界が遮られる、オクルージョンと呼ばれる問題が頻繁に発生し検出精度が低下する。

2.3 群衆密度推定

監視カメラやセンサ機器といったインフラに依存せず、市販の携帯電話端末を用いて群衆の密度を低コストに推定する手法も検討されている。

Bluetooth を用いた密度推定に関する既存研究として文献 [5], [13] があり、特に文献 [5] では、近隣のモバイル端末間で Bluetooth による無線アドホック通信を行い、通信範囲内の端末数や受信電波強度のばらつきをもとに、ユーザ周辺の群衆の密度を推定しているが、WiFi による位置推定手法を応用した前述の手法と同様に、参加者と、Bluetooth 通信をオンにしている端末の絶対数を利用しているため、前述の手法と同様の課題が生じる。他に GPS 情報を用いて密度推定を行う手法も存在し、有名なものとして文献 [14], [15] があり、屋外かつ広域の推定が行われているが、端末の絶対数からの推定であるため、これも同様の課題が生じる。

文献 [16] では、携帯電話端末が接続している基地局の情報を利用して、都市間における人の移動をモデル化している。基地局情報を利用することで、端末間のアドホック通信やセンシングなどを行うことなく低コストに群衆密度を推定することができるが、基地局測位による端末位置の推定精度は数百 m 程度であり、屋内の各エリアにおける混雑状況の把握を目的とする提案手法とは想定するスケールが異なる。文献 [17] では、携帯電話端末間で音声ビーコンによる通信を行うことにより、環境内に存在する端末の数を高精度に推定する手法を提案している。端末間で送受信するビーコンに含めるデータの符号化アルゴリズムを工夫することにより、端末数が多い環境でもロバストな推定を行うことができるが、Bluetooth と同様に、サービスに参加していない人の存在を認識することはできないため、サービス参加が低い環境で群衆の密度を高精度に推定することは難しい。また、移動に負担をとまなう人々に対して歩きやすい経路を案内するハンディキャップナビゲーションや、目的地までの正確な所要時間の予測を実現するためには、群衆の密度に加えて、人の流れのスムーズさなど、群衆の動きの特性まで把握できることが望ましい。既存の群衆密度推定手法は、環境内の人の数や密度のみを推定の対象としており、上記のような詳細な状況把握は難しい。

2.4 音声情報を用いた環境認識

モバイル端末に内蔵されたマイクから取得される音声情報を用いて、位置や環境の認識を行う試みもさかんに行われている。Ear-phone [18] では、携帯電話端末を用いた参加型センシングによって都市部における騒音情報を収集し、その結果を地図上へマッピングすることで、騒音公害の軽減に向けた都市計画の支援を目指している。文献 [19] では、環境音の特徴をフィンガープリントとして用いることで、建物内において部屋単位の位置推定を実現している。

SoundSense [20] では、携帯電話端末から取得した音声情報に対して機械学習アルゴリズムを適用することで、「音楽」、「会話」といった音のタイプと、「歩行」や「車の運転」といったイベントの検出を行い、音声ベースのコンテキスト推定を可能にしている。提案手法では、モバイル端末の処理性能の制約を考慮し、特定の周波数帯の音の大きさをもとに混雑情報の分類を行うシンプルなアルゴリズムを用いているが、上記の手法のように、音声イベントの認識と環境ごとのフィンガープリントを活用すれば、より粒度の高い混雑推定を実現することができると考えられる。

2.5 本研究の位置づけ

提案手法では、スマートフォン端末の複数のセンサを用いて周辺の混雑状況に応じた人の動きの特徴や周辺環境をセンシングし、環境内の複数の端末から収集された情報をサーバ上で集約・統合することでエリアごとの混雑状況を判定する。環境内を歩行する人の動きを分析の対象とすることで、人の密度に加え、エリア内の歩きやすさや移動に要する時間といった詳細な状況の把握が可能となる。また加速度情報やマイクといった端末に内蔵されたセンサのみを用いて混雑度を推定するため、文献 [5] の手法のように周囲の端末との通信を必要せず、サービスへの参加率が低い環境においても個々の端末上で周辺の混雑情報を推定することができる。インフラ（設置型設備）や、歩行者が各自の視覚情報から混雑度を判断し、それを入力して送信する行為などに依存せず市販のモバイル端末から取得可能なセンサ情報のみを用いて群衆の密度および移動の振舞いを認識する手法は、我々の知る限りではこれまでに提案されていない。また、提案手法のアプリケーションを導入した各携帯端末によるセンシング結果をサーバ上へ集約し、複数のクライアントの混雑推定結果を多数決アルゴリズムに基づき統合することで、一部の端末による外れ値の影響を軽減し、さらなる精度向上を実現している点も [5], [17] といった既存手法とは異なる。

3. 提案手法

本章では、まず提案手法で用いる混雑情報の定義について述べ、その後システム全体のアーキテクチャおよび推定方法について説明する。

3.1 混雑情報の定義

群衆密度の低い空間では、ある方向に進む歩行者が、他の歩行者の行動にほとんど影響されることなく、自分に合った速度や経路で移動することができる。しかし歩行者の密度が高くなるにつれて、他の歩行者との干渉により速度や方向を変える機会が増え始め、最終的には群衆の一員として周囲の歩行者と同じ速度で歩くようになる。文献 [21] では、群衆密度の増加と歩行速度の関係が分析されており、




図 1 群衆密度と歩行速度の関係 [21]

Fig. 1 Relation between crowd density and walking speed [21].



図 2 群衆密度 (低)

Fig. 2 Crowd density (Low).



図 3 群衆密度 (中)

Fig. 3 Crowd density (Medium).

群衆密度が増加するにともない、歩行者の歩行速度の自由度が低下し、流れが一様になることが示されている。群衆密度の変化とそれにもなう歩行速度の変化を図 1 に示す。同図より、歩行者密度が 1.0 人/m² 未満の場合には、元の歩行速度の 75~80% 程度の歩行速度で移動できていることが分かる。しかし、群衆密度がさらに増加すると、急激に歩行速度が低下し、群衆密度が 2.5 人/m² の場合には、元の速度の 20% 程度となる。歩行者密度が 2.5 人/m² 以上になると集団転倒などの事故の危険性が高まる。

これらの知見に基づき、本論文では、単位面積あたりの歩行者の数 (群衆密度) を基準として、クライアント周辺の混雑状況を以下のカテゴリに分類する。

群衆密度 (低)

群衆密度が 1.0 人/m² 未満 (図 2)

群衆密度 (中)

群衆密度が 1.0 人/m²~2.5 人/m² (図 3)

群衆密度 (高)

群衆密度が 2.5 人/m² 以上 (図 4)



図 4 群衆密度 (高)

Fig. 4 Crowd density (High).




図 5 混雑度のカテゴリ

Fig. 5 Categories of congestion.

また文献 [22] では歩行者の流動の際、交差の有無によって生じる負荷について分析が行われており、複数の群衆がすれ違う際には小さな負荷が生じ、動線が交差する際には大きな負荷を生じることが指摘されている。そのため歩行者の動線が多く交差するような場所は、危険性が高く、歩行時の快適性が低いといえる。このため、目的地までの所要時間に基づく経路案内や、経路上の歩きやすさを考慮したハンディキャップナビゲーションにおいては、空間内の人の密度に加えて、群衆の移動の振舞いの把握が求められる。この観点から、提案手法では、個々の歩行者の移動方向の差を基準として、歩行流の交差が起りやすい群衆密度 (高) をさらに以下の 2 つのカテゴリに細分化する。ここで、エリア内の歩行者間の移動方向の差 θ_i を小さい順に並べたものを $\theta_1, \theta_2, \dots, \theta_w$ ($w = \frac{K(K-1)}{2}$) とする。このとき、 $[0.7w]$ 番目の要素 θ_s が 45° 未満のとき群衆密度 (高/直線)、 45° 以上であるとき、群衆密度 (高/交差) と定義する。群衆が図 5 (a) のようにほぼ一定の方向へ向かって移動している群衆密度 (高/直線) に対して、同図 (b) のような群衆密度 (高/交差) では異なる方向へ向かう人々との衝突が発生する可能性が高いため、より歩きにくく、歩行に困難がともなう人々にとって危険度の高い状況であると考えられる。

3.2 システムの概要

提案手法では、クライアントが取得した加速度情報を用いて群衆密度 (低・中)、群衆密度 (高/直線)、群衆密度 (高/交差) の 3 つのカテゴリの判別を行う。一方、音声情報に基づく混雑推定では、群衆密度 (低)、群衆密度 (中) お

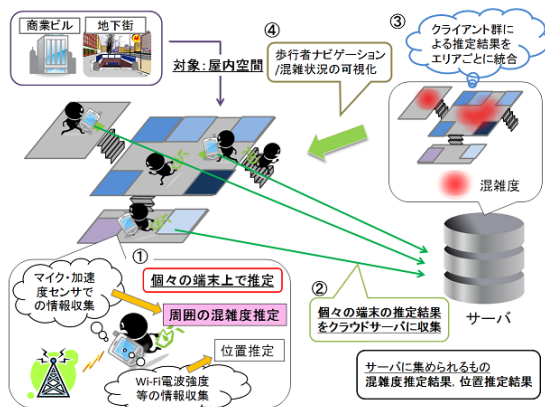


図 6 提案システムのアーキテクチャ

Fig. 6 Architecture of the proposed system.

よび群衆密度 (高) の 3 つのカテゴリを判別する. これら 2 つのセンサによる判別結果を組み合わせることで, クライアント周辺の混雑状況の推定を, 群衆密度 (低), 群衆密度 (中), 群衆密度 (高/直線), 群衆密度 (高/交差) の 4 つのカテゴリに分類する.

提案システムのアーキテクチャを図 6 に示す. システムは, スマートフォン上で動作する 1 台以上のクライアントと, センシングされた混雑情報を集約するクラウドサーバから構成される. クライアントは, 加速度センサから 20 ミリ秒ごとに計測値を取得し, 過去一定期間の計測値の履歴を端末上で分析を行い, またマイクから継続的に周辺音を取集し, 20 ミリ秒を 1 フレームとした周波数成分解析を行うことで, クライアント周辺の混雑状況を分類する (図 6 中の (1)). 加速度情報および音声情報をもとに混雑度および移動状況を推定するための特徴量とアルゴリズムについては 4 章で説明する.

また, 各クライアントは継続的に加速度をモニタしているため, これを PDR にも用いることで, 歩行軌跡情報が得られる [9]. WiFi などを用いた測位とこの PDR を併用することで, おおよその位置情報を得ることができるため, 提案アーキテクチャではそのような位置情報を前提とし, 各クライアント i は, 各時刻 t における位置情報と混雑推定結果の組 $(p_{i,t}, c_{i,t})$ を携帯電話網または WiFi ネットワークを通じて定期的にサーバへ送信する (図 6 中の (2)).

サーバ上では, クライアント群から収集したローカルな混雑推定結果を, 位置情報をもとにエリアごとに集約することで, 各エリアにおけるリアルタイムな混雑状況を推定する (図 6 中の (3)). エリアは, 必要とされる混雑情報の粒度に応じて, 各エリアのサービス提供者によって人為的に定義されるものとし, 各エリアのサイズは端末の位置推定精度に比べて十分に大きいものと仮定する. なお, 通路の道幅が変化する地点や, 改札・階段などのある場所においては, 混雑状況が局所的に大きく変化することが想定

される. 混雑情報の推定精度を高めるためには, 建物の構造を考慮し, 同一エリア内の混雑情報が可能な限り均一となるようにエリアを定義することが望ましい. それぞれのクライアントによる混雑推定結果には, 端末の保持方法などに起因する加速度のノイズや人の動きの個人差によって誤差が生じる可能性があるが, 提案手法では, このようにサーバ上で多数のクライアントのセンシング結果を集約することで, 個々のクライアントの誤差が最終的な混雑推定精度に与える影響の軽減を図る. 複数のクライアントから収集した混雑推定結果を統合し, エリアごとの混雑情報を推定するアルゴリズムについては 4.6 節で述べる.

以上により推定したエリアごとの混雑情報を, 目的地までの移動時間の予測や歩行者ナビゲーション, 対象領域全体の混雑状況の可視化といったアプリケーションに応用することを想定している (図 1 中の (4)).

本システムの参加者は, 自身の周辺の混雑情報をサーバに報告すると同時に, 統合された混雑情報を活用する利用者でもある. なお本システムでは各地点について少なくとも 1 人の参加者が通過すればその地点の混雑状況が把握できるため, 参加者からの位置情報を集約して人密度を推定する方法などと比較し, 少ない参加者で実現できるメリットがある. ただし, 計測精度および対象領域のカバー率の観点からはなるべく多くの参加者が計測することが望ましいといえる.

3.3 混雑判定の対象領域

一般に, 地下街や駅前, ビルのような移動空間は, (1) 通路, (2) 広場や改札前のような自由空間, (3) エスカレータ, エレベータおよび階段のような移動用機器あるいは昇降路で構成されると考えられる. 本論文では, 対象領域において最も多くの面積を占めると想定される通路に着目し, 混雑推定モデルの設計と評価を行う.

4. クライアント周辺の混雑推定方法

4.1 加速度情報による特徴量の定義

モバイル端末を保持する歩行者の行動に応じたセンサ情報の特性を調べるため, 加速度センサ, 電子コンパス, およびジャイロセンサの計測値を収集する Android アプリケーションを実装し, 大阪市営地下鉄御堂筋線梅田駅周辺の地下街エリアにおいて Android 端末 (Nexus S) を用いた予備実験を実施した. 実験用アプリケーションでは, 上記の 3 種類のセンサの計測値をそれぞれ 20 ミリ秒ごとに取得し, 端末上のストレージに保存する. 予備実験では, 1 人の被験者が実験用端末を体の前方に把持した状態で, 群衆密度 (低・中), 群衆密度 (高/直線), 群衆密度 (高/交差) の各混雑状況において, それぞれ約 100 分間歩行し, 移動中のセンサ計測値のログを収集した.

実験によって得られたセンサ情報を分析した結果, 混雑




図 7 混雑状況別のステップ間隔の遷移

Fig. 7 Step intervals with different crowd densities.

状況に応じて歩行時の1歩ごとの時間間隔(ステップ間隔)に特徴が表れることが分かった。それぞれの混雑状況におけるステップ間隔の時間変化を図7に示す。群衆密度(低・中)時と群衆密度(高/直線)時におけるステップ間隔に着目すると、いずれもステップ間隔のばらつきが比較的小さいことが分かる。一方、群衆密度(高/交差)時にはステップ間隔が時間とともに大きくばらついている。これは、異なる方向に向かう人々との衝突を避けるために、一時的に歩行速度を落としたり、立ち止まったりする動作に起因している。また、群衆密度(高/直線)時および群衆密度(高/交差)時には、群衆密度(低・中)時に比べてステップ間隔が平均的に長くなっている。このように、混雑時には、周囲の人の流れに合わせて歩行するため、歩行速度が平時と比べて低下する傾向がある。提案手法では、これらの知見に基づき、加速度情報から検出したステップ間の時間間隔を特徴量として混雑状況の分類を行う。歩行時のステップは、端末の保持方法に依存せず高い精度で推定できることが知られている[10]。このため、ステップ間隔を特徴量として用いることで、特定の端末保持方法を仮定することが難しい実環境においても、混雑状況をロバストに推定することができると考えられる。加速度データから歩行時のステップを検出するためのアルゴリズムについては4.2節、ステップ間隔に基づき歩行者周辺の混雑状況を推定するためのアルゴリズムについては4.4節でそれぞれ述べる。

4.2 ステップ間隔の検出

本節では、クライアントにより取得された加速度データから、歩行時のステップ間隔を検出する方法について述べる。端末を手に把持して歩行した際の鉛直方向加速度の時間変化をプロットしたグラフを図8に示す。同図より、加速度センサから取得される計測値には、端末の微小な振動などに起因する小さなノイズが含まれていることが分かる。こうしたノイズに起因してステップの誤検出や検出漏れが発生することを防ぐため、提案手法では、はじめにセンサ計測値に対して移動平均フィルタを適用することで、




図 8 歩行時の鉛直方向加速度 (移動平均フィルタ適用前)

Fig. 8 Vertical acceleration during walking motion (Before applying the moving average filter).




図 9 歩行時の鉛直方向加速度 (移動平均フィルタ適用後)

Fig. 9 Vertical acceleration during walking motion (After applying the moving average filter).

加速度データのノイズを軽減させる。

加速度センサから取得した k 番目の鉛直加速度サンプルを A_k 、最新の加速度サンプルを A_m とすると移動平均 MA_m は式(1)により定義される。

$$MA_m = \frac{A_m + A_{m-1} + \dots + A_{m-n+1}}{n} \quad (1)$$

提案手法では、新しい加速度サンプルが取得されるたび、過去 n 個の加速度サンプルを利用して移動平均を算出する。なお、本論文では $n = 10$ とする。移動平均フィルタを適用した後の鉛直方向加速度(図9)では、図8で見られた加速度の微小なばらつきが軽減されていることが確認できる。

歩行時には、地面から足が離れる瞬間に鉛直方向上向きの加速度が最大になることが知られている。そこで提案手法では、鉛直方向加速度のピーク値を発見することで歩行時のステップを検出する。以上により検出されたステップ間の時間間隔をステップ間隔と定義し、4.4節で述べる混雑推定アルゴリズムの特徴量として利用する。

4.3 音声情報による特徴量の定義

群衆密度に応じた環境音の特徴を調べるため、3.4.1項の予備実験と同一のエリアにおいて、Android 端末上で音声




図 10 群衆密度 (低) におけるスペクトログラム
Fig. 10 Spectrogram with crowd density (Low).




図 12 群衆密度 (高) におけるスペクトログラム
Fig. 12 Spectrogram with crowd density (High).




図 11 群衆密度 (中) におけるスペクトログラム
Fig. 11 Spectrogram with crowd density (Medium).




図 13 周波数ごとの振幅スペクトルの平均値
Fig. 13 Average amplitude spectrum with each crowd density.

情報を収集する予備実験を実施した。群衆密度 (低), 群衆密度 (中), および群衆密度 (高) の各混雑状況において, 1 人の被験者が実験用端末 (Nexus S) を体の前方に把持した状態で, それぞれ 120 分間歩行し, 移動中の周囲の環境音を端末に内蔵されたマイクによって収集した。

以上の実験により得られた音声データに FFT を適用し, 各周波数成分の振幅スペクトルを調べた。3 通りの混雑状況における 1 分間の環境音のスペクトログラムを, それぞれ図 10, 図 11, 図 12 に示す。同図では, 横軸が時間, 縦軸が周波数, 色調が各周波数成分の振幅を表している。

なお, FFT のフレームサイズは 20 ミリ秒とした。これらの結果より, 群衆密度が高くなるにつれ, 10 kHz 以下の周波数帯において赤色の領域が増加し, 大きな振幅スペクトルが観測されていることが確認できる。また, 4 kHz 以下の周波数成分の振幅スペクトルの平均を図 13 に示す。群衆密度が高いほど, 雑踏音や人の会話音といった環境ノイズが大きくなるため, 各周波数成分において振幅スペクトルが増加している。特に 0 [Hz] から 2,000 [Hz] の周波数帯では, 群衆密度によって振幅スペクトルに大きな差が現れている。提案手法では, これら知見に基づき, 過去 1 分間の環境音から 0 [Hz] から 2,000 [Hz] の周波数成分を抽出し, これらの周波数帯における振幅スペクトルの総和を混

雑推定のための特徴量として利用する。音声情報に基づき歩行者周辺の混雑状況を推定するためのアルゴリズムについては 4.5 節で述べる。

4.4 加速度情報による混雑度推定アルゴリズム

本節では, 4.2 節のステップ検出アルゴリズムにより推定したステップ間隔を利用し, クライアント周辺の混雑状況を群衆密度 (低・中)・群衆密度 (高/直線)・群衆密度 (高/交差) の 3 つのカテゴリに分類するためのアルゴリズムについて述べる。4.1 節で述べたように, 提案手法では, 歩行速度と歩行リズムの 2 つの特徴量に基づき, 混雑状況を 3 つのカテゴリに分類する。ここで, 予備実験の結果をもとに算出した群衆密度 (低・中), 群衆密度 (高/直線), および群衆密度 (高/交差) におけるステップ間隔のヒストグラムと累積分布をそれぞれ図 14, 図 15, 図 16 に示す。

群衆密度 (低・中) 時には 80% 以上の割合でステップ間隔が 0.6 秒以下となっているのに対し, 群衆密度 (高/直線) 時および群衆密度 (高/交差) 時には, その割合が約 30% 程度となっており, 混雑状況に応じて, ステップ間隔の分布が大きく異なっている。そこで, 歩行速度については, 過去 N 歩の歩行動作の中でステップ間隔が 0.6 秒未満となる割合が 80% 以上であるとき *NORMAL*, それ以外のとき *SLOW* とラベル付けするものとする。また, 群衆密度 (高/交差) 時には, 群衆密度 (高/直線) 時に比べて, ステップ




図 14 群衆密度 (低・中) におけるステップ間隔のヒストグラムと累積分布

Fig. 14 Cumulative distribution and histogram of step intervals with crowd density (Low and Middle).




図 15 群衆密度 (高/直線) におけるステップ間隔のヒストグラムと累積分布

Fig. 15 Cumulative distribution and histogram of step intervals with crowd density (High/Straight).




図 16 群衆密度 (高/交差) におけるステップ間隔のヒストグラムと累積分布

Fig. 16 Cumulative distribution and histogram of step intervals with crowd density (High/Intersection).

間隔が 0.8 秒以上 3.0 秒未満となる頻度が高くなっている。これは、異なる方向に向かう人々との衝突を避けるため、一時的に歩行速度を落としたり、立ち止まったりする動作に起因している。そこで、歩行リズムについては、過去 N 歩の歩行動作の中で、ステップ間隔が 0.8 秒以上 3.0 秒未満となる割合が 20% 未満であるとき *NORMAL*、それ以外るとき *IRREGULAR* とラベル付ける。新たなステップ

表 1 混雑度推定ルール

Table 1 Rules for acceleration-based congestion estimation.

歩行速度	歩行リズム	混雑状況
NORMAL	NORMAL	群衆密度 (低・中)
NORMAL	IRREGULAR	群衆密度 (低・中)
SLOW	NORMAL	群衆密度 (高/直線)
SLOW	IRREGULAR	群衆密度 (高/交差)




図 17 特徴量の累積確率

Fig. 17 Cumulative distribution of audio-based feature values.

が検出されるたびに過去 10 回 ($N=10$) のステップ間隔をもとに歩行速度および歩行リズムをそれぞれ 2 つのカテゴリに分類し、表 1 の推定ルールに基づき、クライアント周辺の混雑状況を推定する。

4.5 音声情報による混雑推定アルゴリズム

本節では、4.3 節で定義した環境音の特徴量に基づきクライアント周辺の混雑状況を群衆密度 (低)、群衆密度 (中) および群衆密度 (高) の 3 つのカテゴリに分類するためのアルゴリズムについて述べる。前述のとおり、提案手法では、過去 1 分間の環境音データに対して FFT を適用することで、周波数ごとの振幅スペクトルを求め、0~2kHz のスペクトル値の総和によって特徴量を定義する。ここで、予備実験で収集した 120 分間の音声データを 1 分ごとに分割することで 120 個の環境音データを生成し、特徴量の累積分布を求めた結果を図 17 に示す。

群衆密度のカテゴリに応じて、特徴量の分布に大きな違いが現れていることが分かる。そこで提案手法では、予備実験で収集した環境音情報を学習データとして利用し、一般的な機械学習アルゴリズムの 1 つである K 近傍法 [23] を用いて、環境音の特徴量から混雑状況のカテゴリを判別するための分類器を構成する。クライアント端末で観測された環境音データから前述の特徴量を抽出し、この分類器に入力することで、クライアント周辺の混雑情報カテゴリを端末上でローカルに推定することが可能である。

4.6 エリア内の混雑推定結果の集約

クライアント上で得られた加速度/音声情報に基づく混雑推定結果は、それぞれ、定期的にサーバへアップロードされる。サーバ上では、クライアント群から収集した過去

表 2 混雑推定結果の統合ルール

Table 2 Rules for data integration.

		加速度による推定結果		
		(低・中)	(高/直線)	(高/交差)
音声による推定結果	(低)	低	低	低
	(中)	中	中	中
	(高)	判定不能	高/直線	高/交差

T 秒間の混雑推定結果の履歴をもとに、以下のような多数決アルゴリズムによって、エリアごとの混雑情報を推定する。ここで、過去 T 秒間にクライアント i によって出力された、加速度または音声情報に基づく混雑推定結果の集合を $U_i = \{(p_{i,1}, c_{i,1}), (p_{i,2}, c_{i,2}), \dots, (p_{i,n}, c_{i,n})\}$ とし、これらのうちエリア A_k 内で観測されたものを $U_{i,k} \subseteq U_i$ とする。また、 $U_{i,k} \neq \phi$ となるような各エリア A_k において、クライアント i によって最も多く観測された混雑情報カテゴリを $\tilde{c}_{i,k}$ とする。提案手法では、過去 T 秒間にエリア内を通行したすべてクライアントによる混雑推定結果 $\{\tilde{c}_{i,k} | U_{i,k} \neq \phi\}$ を集約し、最も多くのクライアントで観測された混雑情報カテゴリを、エリア A_k の最終的な混雑推定結果とする。以上のような多数決アルゴリズムを適用することで、各エリアにおいて、加速度情報に基づく混雑情報カテゴリ（群衆密度（低・中）、群衆密度（高/直線）、群衆密度（高/交差））および音声情報に基づく混雑情報カテゴリ（群衆密度（低）、群衆密度（中）、群衆密度（高））をそれぞれ求める。

4.7 加速度/音声情報に基づく混雑推定結果の統合

最後に、加速度および音声情報による混雑推定結果を、表 2 のルールに基づき統合することで、各エリアの混雑推定結果を群衆密度（低）、群衆密度（中）、群衆密度（高/直線）、群衆密度（高/交差）の 4 つのカテゴリに分類する。なお、加速度情報に基づく混雑推定結果と音声情報に基づく混雑推定結果の間に矛盾が生じた場合には、原則として、音声情報に基づく混雑推定結果を優先する。5 章で議論するように、混雑状況に応じた歩行動作の変化の仕方は、個人によって異なる可能性がある。こうした個人差の影響を受けにくい、音声情報に基づく推定結果をより信頼することで、混雑推定のロバスト性の向上を図っている。ただし、加速度に基づく推定結果が群衆密度（低/中）となり、音声に基づく推定結果が群衆密度（高）となった場合には、前述の 4 つの混雑情報カテゴリへの分類が困難であることから、判定不能とする。

5. 性能評価

提案手法の性能を評価するため、大阪市営地下鉄御堂筋線梅田駅周辺の地下街エリアにおいて Android 端末を用いたフィールド実験を行った。なお、フィールド実験では、



図 18 フィールド実験における端末保持方法
Fig. 18 Student volunteers holding the phones.



図 19 フィールド実験の様子
Fig. 19 Field experiment.

加速度情報と音を同時に記録するアプリケーションを実装して利用した。また、加速度情報から混雑度推定を行う機能も同時に実装したためそれもあわせて利用している。本実験ではオフライン解析を行うためこの機能は不要であるものの、将来的には混雑判定を端末側で実施することでサーバへのデータ通信量を削減する意図があるため、その機能を一部実装したものである。

5.1 フィールド実験

加速度情報に基づく混雑推定の精度を検証するため、12 人の被験者がそれぞれ Android 端末 (Nexus S) を保持し、大阪市営地下鉄御堂筋線梅田駅改札前を起点とする 130 m の通路を 20 回歩行した。この通路は幅 10 m 程度であり、途中に 3 段程度の階段があるがそれ以外に段差はない。また改札前を除き通路の両側に商店が存在する。端末上では提案手法の混雑推定アルゴリズムを実装したアプリケーションを動作させ、被験者周辺の混雑状況を端末上でリアルタイムに推定するとともに、加速度センサの計測値のログを収集した。このとき、各被験者は図 18、図 19 のように端末を体の前方で保持するものとした。以上の実験により得られた各クライアントの混雑推定結果を 3.1 節で定義される実際の混雑状況と比較し、正解率を評価した。ま

た、12人の被験者がつねに同一のエリアにいると想定し、すべてのクライアントによる混雑推定結果を4.6節のアルゴリズムを用いて統合した場合の正解率についても評価を行った。

さらに、音声情報に基づく混雑推定の精度を検証するため、12人の被験者から、上記の加速度情報の取得中に、3.1節で定義した3通りの混雑状況において、それぞれ1分間の環境音データを計120回取得し、4.5節のアルゴリズムによって混雑情報の推定を行った。

なお、今回のシステムでは加速度および音声情報による推定はそれぞれ独立で行っており、それぞれの推定結果を4.7節の手法を用いて統合を行ったが、その具体的な方法については後述する。

5.2 単一のクライアントによる周辺混雑情報の推定

5.2.1 加速度情報に基づく混雑推定

各クライアントによる加速度情報に基づく混雑推定結果の混同行列を表3に示す。縦の列が実際の混雑状況、横の列が混雑推定結果に対応し、セルの値がそれぞれの混雑状況において各クライアントが出力した混雑推定結果の割合を表している。なお、表の中の対角成分が、混雑推定結果の正解率に対応する。群衆密度(低・中)時、群衆密度(高/直線)時、および群衆密度(高/交差)時における、各クライアントによる混雑推定精度の平均はそれぞれ75%、75%、71%となり、いずれの混雑状況においてもクライアント周辺の混雑情報を高い精度で推定できることが分かった。また、すべての混雑状況を考慮した本実験における平均混雑推定精度は73%となった。一方、群衆密度(低・中)時には、群衆密度(高/直線)と誤判定される割合が17%と比較的高くなっている。これは、通路の傾斜など周辺の混雑状況以外の要因による歩行速度の変化や、歩行速度の個人差が原因であると考えられる。なお、歩行リズムはこれらの要因によらずつねにほぼ一定であったことから、群衆密度(高/交差)に誤判定される割合は8%程度と低くなっている。また、群衆密度(高/直線)時には、16%の割合で、群衆密度(低・中)との誤判定が発生している。群衆密度(高/直線)時には、周囲の群衆の流れに合わせて移動するため、大半のクライアントにおいて0.6秒よりも長いステップ間隔が頻繁に検出されるが、一部の被験者については周囲の群衆をすり抜けて移動する振舞いが見られた。こうした場合には、歩行速度の低下が発生しないため、群衆密度(低・中)と判定される。群衆密度(高/交差)時には、群衆密度(高/直線)との誤判定の割合が23%と高くなっている。提案手法では、歩行リズムの乱れの有無により群衆密度(高/直線)と群衆密度(高/交差)を判別しているが、周囲の人々との位置関係によっては、他の歩行者との衝突を避ける動きがあまり生じないケースもある。また、他の歩行者を回り込むような経路で歩行した場合には、歩行リズムの乱れ

表3 加速度情報に基づく混雑推定精度(統合前)

Table 3 Accuracy of acceleration-based local congestion estimation by individual clients.

		推定結果		
		(低・中)	(高/直線)	(高/交差)
実際の状況	(低・中)	74.7%	17.1%	8.2%
	(高/直線)	16.3%	75.2%	8.5%
	(高/交差)	6.4%	22.8%	70.8%

表4 音声情報に基づく混雑推定の精度

Table 4 Accuracy of audio-based congestion estimation by individual clients.

		推定結果		
		(低)	(中)	(高)
実際の状況	(低)	63.9%	33.3%	2.8%
	(中)	2.7%	78.4%	18.9%
	(高)	2.1%	16.3%	81.6%

表5 統合後の混雑推定精度

Table 5 Accuracy of acceleration-based congestion estimation after data integration at a server.

		推定結果		
		(低・中)	(高/直線)	(高/交差)
実際の状況	(低・中)	80.3%	12.6%	7.1%
	(高/直線)	13.1%	82.3%	4.6%
	(高/交差)	6.9%	20.7%	72.4%

が生じないため、提案手法による人流交差の検出は困難となる。このように、混雑状況に応じた人の振舞いにはばらつきがあるため、個々のクライアントによる混雑推定結果には、一定の誤差が生じる。

5.2.2 音声情報に基づく混雑推定

5.1節のフィールド実験で取得した音声情報に対して4.5節の機械学習アルゴリズムを適用し、交差検証によって混雑推定精度を評価した。交差検証では取得した音声情報の90%を訓練データ、10%をテストデータとして利用した。以上により得られた混雑推定結果を表4に示す。

群衆密度(低)、群衆密度(中)、および群衆密度(高)の3通りの混雑状況において、正しい混雑推定結果が得られた割合は、それぞれ64%、78%、82%となり、群衆密度(低)以外の混雑状況においては、周辺の混雑情報を高い精度で推定できている。また、すべての混雑状況を考慮した平均精度は75%となった。

5.3 エリア内の混雑推定結果の統合

4.6節のアルゴリズムを用いて、12個のクライアントによる加速度情報に基づく混雑推定結果を統合した場合の精度を表5に示す。いずれの混雑状況においても70%~80%の混雑推定精度が得られており、各クライアントで独立に混雑推定を行った場合と比べて平均約5%改善してい

表 6 加速度および音声情報に基づく混雑推定の精度
Table 6 Accuracy of congestion estimation (merged).

		推定結果				
		(低)	(中)	(高/直線)	(高/交差)	(判定不能)
実際の 状況	(低)	63.9%	33.3%	0.4%	0.2%	2.2%
	(中)	2.7%	78.4%	2.4%	1.3%	15.2%
	(高/直線)	2.1%	16.3%	67.2%	3.8%	10.6%
	(高/交差)	2.1%	15.3%	16.9%	60.1%	5.6%

る。このように、多数のクライアントによる混雑推定結果を統合することによって、個人差などの影響により一部のクライアントで発生する混雑推定誤差の影響を軽減し、エリア内の混雑情報をよりロバストに推定することが可能となっている。一方、音声情報に基づく混雑推定では、複数のクライアントから収集した混雑推定結果を統合することによる精度改善は見られなかった。加速度情報に基づく混雑推定とは異なり、近隣のクライアントによる混雑推定結果に差が生じにくいことがその理由として考えられる。

この手法を利用することで、たとえばショッピングモールの店の前でゆっくり歩いた結果、誤って「混雑」と判定されてしまうような場合などでも、周辺に「非混雑」として移動した歩行者が存在すれば、その場所は通常速度で通過できることを示しているため、「非混雑」と判定できる。このように複数人の推定結果を利用してより推定精度を向上させる方法もあわせて検討している。

5.4 加速度および音声情報に基づく混雑推定結果の統合

加速度情報による推定結果および音声情報による推定結果を、4.7 節の統合ルールによって、統合した結果を表 6 に示す。

加速度および音声による混雑推定結果を統合することにより、混雑状況の 4 つのカテゴリを 60%~70%の精度で判別できていることが分かる。

6. 議論

6.1 考察

5.2 節および 5.2.2 項では、加速度情報および音声情報に基づく混雑推定アルゴリズムによって、それぞれクライアント周辺の群衆密度のカテゴリを高い精度で判別できることを示した。音声情報に基づくアプローチでは、群衆密度をより細かい粒度で推定することができるが、群衆の移動の振舞いを把握することは難しい。一方、加速度情報に基づくアプローチは、音声ベースのアプローチと比較して群衆密度の推定粒度は粗くなるが、人流の交差など、環境内における群衆の動きの特徴を正確にとらえることができる。これら 2 つのアプローチを効果的に組み合わせることで、環境内のきめ細かな状況把握を実現することができると考えられる。

なお、今回対象とした駅地下街以外にも様々な環境下で検証する必要がある。詳細な結果は紙面の都合上省略するが、大阪駅前の大規模商業施設内で同様の実験を行った結果、本論文に掲載した、駅地下街における実験時とほぼ同等の精度である 71% (加速度) と 73% (音) であった。今後も様々な環境下での検証を行っていく予定である。

6.2 統計混雑情報の利用

クライアントの密度が低いエリアでは、複数のクライアントによる混雑推定結果を用いたデータ集約の効果が限定され、少数のクライアントの混雑推定誤差によりエリア内の混雑推定精度が低下する可能性がある。また、クライアントが存在しないエリアにおいては、混雑状況の推定そのものが難しいという課題がある。地下街など公共空間におけるクライアント混入率は、一般に数%~十数%と低いことが想定されるため、こうした状況は頻繁に生じうる。こうした問題を解決するため、クライアントから収集したリアルタイムな混雑情報情報に加えて、各エリアにおける過去の同一時間帯の混雑情報の履歴(統計混雑情報)を活用して最終的な混雑情報を決定することを検討している。サーバ上でエリアごとの混雑情報の推定を行う際に、過去の同一時間帯におけるエリア内の混雑推定結果をもとに現在の混雑状況を予測し、予測結果とクライアント群から収集したリアルタイムな混雑推定結果の重み付き平均によって最終的な混雑推定結果を求める。エリア内のクライアント数が多い場合には、クライアント群から収集したリアルタイムな混雑情報情報の重みを大きくする一方、エリア内のクライアント数が少ない場合には統計混雑情報に基づく予測値の重みを大きくして不足する情報を補うなど、状況に応じて重みを動的に変化させることで、混雑推定のロバスト性を改善することができると考えられる。

6.3 個人差の影響の軽減

混雑推定の精度に影響を与えうる要因の 1 つとして、歩行動作の個人差が考えられる。実際に、5 章のフィールド実験においても、平時のステップ間隔が他の被験者に比べて極端に長い一部のクライアントで、群衆密度(低・中)の検出精度が極端に低下する事例が見られた。しかしながら、混雑時における歩行速度の低下や、人流が交差する地点における歩行リズムのばらつきといった一般的な傾向は、これらの被験者においても同様に確認された。また保持方法が異なることも考えられる。したがって、こうした個人差や保持方法の影響を軽減するためには、混雑推定のためのパラメータを個人別に調整したり、加速度の重力方向によって保持姿勢の影響を排除するアプローチなどが有効であると考えられる。

たとえば、過去のステップ間隔の履歴の中で最も高い頻度で観測された値を基準とし、基準値からの差分によって

閾値を定義すれば、歩行速度の個人差の影響をある程度軽減できると考えられる。日常生活の中で、混雑した環境に滞在している時間の割合は一般にきわめて小さいと想定されるため、十分に長い期間のステップ間隔の履歴を考慮することで、個人に適した閾値を決定できると考えられる。

7. あとがき

本論文では、スマートフォンを活用した屋内環境における混雑センシング手法を提案した。提案手法では、群衆密度に応じた人間の歩行動作と周囲の環境音の特徴を事前実験に基づきモデル化することで、スマートフォンに内蔵された加速度センサおよびマイクから得られる測定情報をもとに、クライアント周辺の混雑状況をリアルタイムに推定する。Android 端末を用いた実測実験により、クライアント周辺の混雑状況を平均約 70%の精度で推定できることを示した。

今後の課題として、6章で述べたような統計混雑情報を活用したロバスト性の向上に取り組んでいきたいと考えている。また本論文では、通路を対象とした混雑推定モデルを構成したが、今後、階段や改札など、一般的な地下街で想定される様々な場所タイプについて同様の混雑情報推定モデルを検討していく予定である。さらに、加速度センサやマイクに加えて、電子コンパス、ジャイロセンサ、Bluetooth の受信電波強度に基づく近隣クライアント間の近接情報など、スマートフォン端末上で取得可能な他のセンサ情報を併用することで、混雑情報推定精度の改善を図っていく。

謝辞 本研究の一部は、KDDI 財団ならび文部科学省国家課題対応型研究開発推進事業—次世代 IT 基盤構築のための研究開発—「社会システム・サービスの最適化のための IT 統合システムの構築」(2012 年度～2016 年度)の助成を受けたものです。お礼申し上げます。

参考文献

- [1] Arikawa, M., Konomi, S. and Ohnishi, K.: Navitime: Supporting Pedestrian Navigation in the Real World, *IEEE Pervasive Computing*, Vol.6, No.3, pp.21-29 (2007).
- [2] Enzweiler, M. and Gavrilu, D.M.: Monocular Pedestrian Detection: Survey and Experiments, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.31, No.12, pp.2179-2195 (2009).
- [3] 山下倫央, 副田俊介, 野田五十樹: 人流計測による避難誘導効果の実証的検証, 情報処理学会研究報告, Vol.2009, No.25, pp.1-8 (2009).
- [4] 新村貴彦, 新井啓之, 井上 潮: 確率的予測に基づく人流計測, 情報処理学会研究報告, Vol.2004, No.26, pp.119-124 (2004).
- [5] Weppner, J. and Lukowicz, P.: Collaborative Crowd Density Estimation with Mobile Phones, *Proc. 9th ACM Conf. Embedded Networked Sensor Systems* (2011).
- [6] Rekimoto, J., Shionozaki, A., Sueyoshi, T. and Miyaki, T.: PlaceEngine: A WiFi Location Platform Based on Realworld Folksonomy, *Proc. Internet Conference*, Vol.2006, pp.95-104 (2006).
- [7] Yin, J., Yang, Q. and Ni, L.M.: Learning Adaptive Temporal Radio Maps for Signal-Strength-Based Location Estimation, *IEEE Trans. Mobile Computing*, Vol.7, No.7, pp.869-883 (2008).
- [8] Steinhoff, U. and Schiele, B.: Dead Reckoning from the Pocket an Experimental Study, *Proc. 8th International Conference on Pervasive Computing and Communications (PerCom '10)*, pp.162-170 (2010).
- [9] Woodman, O. and Harle, R.: Pedestrian localisation for indoor environments, *Proc. 10th International Conference on Ubiquitous computing (UbiComp '08)*, pp.114-123 (2008).
- [10] Li, F., Zhao, C., Ding, G., Gong, J., Liu, C. and Zhao, F.: A Reliable and Accurate Indoor Localization Method Using Phone Inertial Sensors, *Proc. 14th International Conference on Ubiquitous Computing (UbiComp '12)*, pp.421-430 (2012).
- [11] Constandache, I., Choudhury, R.R. and Rhee, I.: Towards Mobile Phone Localization without War-Driving, *Proc. 29th International Conference on Computer Communications (INFOCOM '10)*, pp.1-9 (2010).
- [12] Zhao, H. and Shibasaki, R.: A Novel System for Tracking Pedestrians Using Multiple Single-Row Laser-Range Scanners, *IEEE Trans. Systems, Man and Cybernetics, Part A: Systems and Humans*, Vol.35, No.2, pp.283-291 (2005).
- [13] Ghose, A., Bhaumik, C. and Chakravarty, T.: BlueEye: A System for Proximity Detection Using Bluetooth on Mobile Phones, *Proc. 2013 ACM Conference on Pervasive and Ubiquitous Computing Adjunct Publication*, ACM, pp.1135-1142 (2013).
- [14] 株式会社ゼンリンデータコム: いつも NAVI ラボ混雑度マップ, 入手先 (<http://lab.its-mo.com/densitymap/index.html>).
- [15] Reades, J., Calabrese, F., Sevtsuk, A. and Ratti, C.: Cellular Census: Explorations in Urban Data Collection, *Pervasive Computing*, Vol.6, No.3, pp.30-38, IEEE (2007).
- [16] Isaacman, S., Becker, R., Cáceres, R., Martonosi, M., Rowland, J., Varshavsky, A. and Willinger, W.: Human Mobility Modeling at Metropolitan Scales, *Proc. 10th International Conference on Mobile Systems, Applications and Services (MobiSys '12)*, pp.239-252 (2012).
- [17] Kannan, P.G., Venkatagiri, S.P., Chan, M.C., Ananda, A.L. and Peh, L.-S.: Low Cost Crowd Counting Using Audio Tones, *Proc. 10th ACM Conference on Embedded Network Sensor Systems (SenSys '12)*, pp.155-168 (2012).
- [18] Rana, R.K., Chou, C.T., Kanhere, S.S., Bulusu, N. and Hu, W.: Ear-phone: An End-to-End Participatory Urban Noise Mappingsystem, *Proc. 9th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN '10)*, pp.105-116 (2010).
- [19] Tarzia, S.P., Dinda, P.A., Dick, R.P. and Memik, G.: Indoor Localization without Infrastructure Using the Acoustic Background Spectrum, *Proc. 9th International Conference on Mobile Systems, Applications, and Services (MobiSys '11)*, pp.155-168 (2011).
- [20] Lu, H., Pan, W., Lane, N.D., Choudhury, T. and Campbell, A.T.: SoundSense: Scalable Sound Sensing for People-Centric Applications on Mobile Phones, *Proc. 7th International Conference on Mobile Systems, Applications, and Services (MobiSys '09)*, pp.165-178 (2009).
- [21] Older, S.: *Movement of Pedestrians on Footways in*

- Shopping Streets*, Traffic engineering & control (1968).
- [22] 高柳英明, 佐野友紀, 渡辺仁史: 群集交差流動における歩行領域確保に関する研究: 歩行領域モデルを用いた解析, 日本建築学会計画系論文集, No.549, pp.185–191 (2001).
- [23] Larose, D.T.: *Discovering Knowledge in Data: An Introduction to Data Mining*, pp.90–106, Wiley Online Library (2005).

推薦文

音センサや加速度センサを用いた混雑度センシング手法を提案しており, そのアルゴリズムは精緻で興味深い. 実験では実環境でのデータを用いて有効性を評価しており, 論文としての完成度も高い. よって, ここに研究会推薦論文として推薦する.

(モバイルコンピューティングとユビキタス通信研究会主査
渡邊 晃)



東野 輝夫 (フェロー)

昭和 54 年大阪大学基礎工学部情報工学科卒業. 昭和 59 年同大学大学院基礎工学研究科博士後期課程修了. 同年同大学助手. 現在, 同大学大学院情報科学研究科教授. 博士 (工学). 分散システム, 通信プロトコル, モバイルコンピューティング等の研究に従事. 電子情報通信学会, ACM 各会員. IEEE Senior Member.



西村 友洋 (学生会員)

平成 25 年大阪大学基礎工学部情報科学科卒業. 同年同大学大学院情報科学研究科博士前期課程進学. スマートフォンを活用した屋内環境における混雑センシングに従事.



樋口 雄大 (学生会員)

平成 22 年大阪大学基礎工学部情報科学科卒業. 平成 26 年同大学大学院情報科学研究科博士後期課程修了. 同年より同大学院情報科学研究科特任助教. 博士 (情報科学). モバイル/パーベイシブコンピューティングに関する

研究に従事.



山口 弘純 (正会員)

平成 6 年大阪大学基礎工学部情報工学科卒業. 平成 10 年同大学大学院基礎工学研究科博士後期課程修了. 同年オタワ大学客員研究員. 平成 11 年大阪大学大学院基礎工学研究科助手. 平成 14 年同大学院情報科学研究科助手.

平成 19 年より同大学院情報科学研究科准教授. 博士 (工学). モバイルコンピューティング等に関する研究に従事. IEEE, 電子情報通信学会各会員.