

グループ行動コンテキストを活用した 近隣スマートフォンユーザ群の位置関係認識

樋口 雄大^{†1} 山口 弘純^{†1,†2} 東野 輝夫^{†1,†2}

本稿では、混雑した環境において、周囲の人々との位置関係を直感的に認識するためのソーシャルナビゲーションフレームワーク People-centric Navigation (PCN) を提案する。PCN は dead reckoning と Bluetooth による近接センシングの組み合わせにより、携帯電話端末に搭載された機能のみを用いて近隣ユーザ間の相対位置を推定する。センサ情報の履歴をもとにユーザ群のグループ行動を検出し、グループ内における移動軌跡の類似性や近接性を利用してセンサノイズ等に起因する誤差の影響を軽減することで、認識性の高い位置情報の提供を実現している。Android 端末を用いたフィールド実験を通して、提案手法の実環境における有効性を示した。

People-centric Neighbor Recognition by Context-based Grouping

TAKAMASA HIGUCHI,^{†1} HIROZUMI YAMAGUCHI^{†1,†2}
and TERUO HIGASHINO^{†1,†2}

This paper presents People-centric Navigation (PCN) system, which supports people to recognize nearby smartphone users in a crowd. PCN integrates pedestrian dead reckoning and proximity sensing by Bluetooth to estimate their relative positions using off-the-shelf mobile phones. Since positioning accuracy is hard to improve without assistance of dedicated devices, our primary aim is to alleviate the impact of position errors on mobile social navigation. To achieve this goal, we employ the concept of group activity recognition that greatly helps to correct relative position errors in various situations. Through a field experiment in a real exhibition, we have shown the efficacy of our concept.

^{†1} 大阪大学大学院情報科学研究科

Graduate School of Information Science and Technology, Osaka University, Japan

^{†2} 独立行政法人 科学技術振興機構, CREST

Japan Science and Technology Agency, CREST



図1 パーティ会場



図2 モバイルソーシャルナビゲーション

1. はじめに

近年、携帯電話端末を通じて収集した位置情報やセンサ情報を利用してユーザ同士の関わりを支援するモバイルソーシャルアプリケーションが注目を集めている。現在位置を友人間で共有する Foursquare¹⁾ といった商用アプリケーションの普及に加え、複数のユーザ間のインタラクションを検出する²⁾、将来の行動や友人とのコンタクトを予測する³⁾ といった、より高度なアプリケーションも活発に研究されている。従来のモバイルソーシャルアプリケーションの多くは、建物単位といった比較的粒度の粗い位置情報を共有・分析の対象としてきたが、待ち合わせ場所やショッピングモール、パーティ会場など、多くの人々で混み合った場所において、知人のいる場所までユーザを導く **モバイルソーシャルナビゲーション** といったサービスも、人々のインタラクションを支援する上で極めて有用である。

例として、図1のようなパーティ会場を考えてみよう。会場は参加者で混雑しており、図2のように、周囲の人々によってたびたび視界が遮られる。このため、たとえ探している相手が近くにいることがわかっても、実際にその相手を見つけ出すことは難しい。こうした環境でモバイルソーシャルナビゲーションを実現するためには、ユーザ間の位置関係を高精度に把握することが求められる。屋外においては、地図へのマッピングや基準局が発信する電波を併用して GPS を補正することで十分な精度が得られるが、GPS による測位が行えない屋内環境で、高精度な測位を低コストに実現することは一般に難しい。超音波、赤外線、電波等を用いたインフラベースの測位手法は、正しい位置情報が既知である基準局を多数配置する必要があるほか、精度を高めるためにユーザ端末にも専用のデバイスを要求するものが多く、普及が進んでいない。また、商用的に広く利用されている Wi-Fi ベースの測位技術⁴⁾ は、近隣のアクセスポイントからの干渉等によって数 m～数十 m の位置誤差が生じるほか、事前に各地点で電波強度のシグネチャを収集する必要がある。インフラやデバイスの制約のもと、位置関係の直感的な把握を実現するためには、精度そのものの改善に加え、**位**

位置誤差がアプリケーションに与える影響を軽減するアプローチが有効であると考えられる。

この考え方にに基づき、本稿では、混雑した環境下で、周囲の人々との位置関係を直感的に認識するためのソーシャルナビゲーションフレームワーク People-centric Navigation (PCN) を提案する。PCN は、pedestrian dead reckoning (PDR) による移動軌跡推定と端末間における Bluetooth の受信電波強度 (RSS) をもとに、サーバ上で近隣スマートフォンユーザー群の位置関係を推定する。センサノイズ等による軌跡推定誤差やマルチパス伝搬による RSS のゆらぎに起因する位置誤差の影響を軽減するため、我々はユーザー間の行動の類似性に着目した。ソーシャルナビゲーションが必要となる混雑した環境では、一般に、友人や、家族、同僚といった知人同士の集団や、通りや駅において同じ方向に向かう人の流れなど、互いに類似した行動をとる“グループ”が存在する。PCN は加速度センサ、電子コンパスの計測値と Bluetooth RSS の履歴からこうした人々のグループ行動を検出し、グループ情報に基づき推定位置をヒューリスティックに補正することで、位置誤差を軽減する。また、“正面を横切る 3 人組”、“後方に立っている 5 人組”といったグループ行動コンテキストを、近隣ユーザー群を識別するための補助的な情報として活用することで、推定位置に誤差が含まれる場合にも、ユーザー間の位置関係を容易に認識できる仕組みを実現している。

提案手法の性能を評価するため、PCN を Android システム上に実装し、展示会において 20 名の被験者による実証実験を行った。実験の結果から、PCN がユーザー群のグループ行動を高い精度で検出し、グループ情報に基づく補正によって位置推定精度を大幅に改善できることを示した。さらに、推定位置が形成する地理的なクラスと実際のグループとの一貫性から、ユーザーが推定位置を周辺の人々と直感的に対応付けられることも示している。

2. 関連研究

屋内向けのモバイル端末測位技術としては、正しい位置情報を設定した基準局 (アンカ) と専用のユーザー端末を用いた手法が数多く提案されてきた。Active Bat⁵⁾ や Cricket⁶⁾ は、電波と超音波の到達時間差 (TDoA) を利用して、天井や壁に設置された複数のアンカとの距離を推定することで、ユーザー端末の位置を数 cm の精度で推定できる。一方、測位を行うためにはアンカを数 m 間隔で配置する必要があり、導入や運用に多くのコストを要するという課題がある。我々の研究グループでは、歩行者の移動の断続性に着目し、静止している近隣端末の位置情報を用いてアンカを補完することで、より低コストにモバイル端末の測位を実現する手法を提案している⁷⁾。こうした協調型位置推定手法を BeepBeep⁸⁾ といったサウンドベースの測距手法と組み合わせることで、携帯電話端末上でも高精度な位置推定が実

現できると考えられる。ただし、十分な測距精度を得るためにはデバイス依存の調整や環境音の除去が必要となるため、実環境での利用には課題も残されている。また、無線アドホック通信のコネクティビティや受信電波強度 (RSS) のみを用いた低コストな位置推定手法⁹⁾ も提案されているが、屋内環境では無線信号のマルチパス伝播等の影響により精度が著しく低下する場合があります。高い位置精度が求められるアプリケーションには適さない。

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。携帯電話端末上での動作を前提とした手法^{10),11)} も数多く提案されているが、センサノイズ等の影響により、PDR 単独で高い位置推定精度を実現することは一般に難しい。Escort¹²⁾ は、音声ビーコンによって端末同士の遭遇を検出し、各端末の推定軌跡を遭遇地点で重ね合わせることによって、端末間の相対的な位置関係を推定する。提案手法は、PDR による軌跡推定と遭遇情報 (近接センシング) を用いて相対位置推定を実現しているという点で Escort と共通する部分もあるが、Escort が、ショッピングモールやホテルといったはじめて訪れた場所で、そのどこかにいる友人の場所までユーザーを導くことを目的としているのに対し、PCN は人混みの中から友人を見つけるために、周囲の人々との位置関係を直感的に提示することを目指しており、想定環境や目的が大きく異なる。Escort では画像認識を併用して近隣ユーザーとの位置関係の把握を実現しているが、こうした方法はユーザーの負担が大きい。

提案手法のように、携帯電話端末に搭載された機能だけを用いて近隣ユーザー間のソーシャルナビゲーションを実現する手法は、我々の知る限りこれまでに提案されていない。また、フィールド実験に基づく性能評価により、提案手法の実環境における有用性を確認している。

3. 予備実験とシステムの概要

3.1 予備実験

Bluetooth RSS に基づく端末間距離の推定精度、および PDR による軌跡推定精度を検証するため、Google Nexus S を用いた予備実験を実施した。

図 3 は、本学情報科学研究科棟内において、2 台の端末を様々な距離で配置し、端末間の Bluetooth RSS を収集した結果である。電波のマルチパス伝搬や、Wi-Fi など他の無線通信の干渉によって、同じ距離でも RSS は大きくばらついており、端末間の距離を正確に推定することは難しい。一方、強い RSS が観測される頻度は端末間の距離が離れるにつれて低くなり、7m 以上の距離では -70 dBm 以上の RSS は観測されていない。この性質を利用すれば、近傍にいる端末を比較的高い精度で検出することが可能である。

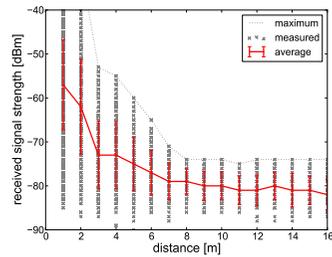


図3 端末間距離と Bluetooth RSS の関係

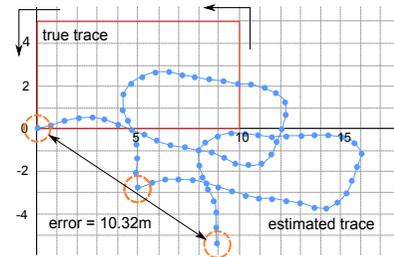


図4 PDR による軌跡推定

次に、シンプルな PDR アプリケーションを実装し、軌跡推定の精度を検証した。歩行時には、ステップのタイミングに同期して、加速度が鉛直方向に大きく変動する。そこで、鉛直方向の加速度があらかじめ定めた閾値を超えるたびに歩数をカウントするとともに、電子コンパスの計測値をもとに、ステップ時の移動方向を推定した。図4は、同研究科棟の室内において、5m×10mの矩形コースを2周歩行した時の軌跡推定結果である。点線で囲まれた場所はそれぞれ同一の地点であり、60m歩行した後は位置誤差が10.32mにまで増大している。このように、センサノイズや端末の保持方法といった要因によって大きな誤差が蓄積されるため、PDR 単独で高精度な位置推定を行うことは困難である。

3.2 PCN システムの概要

PCN のシステムの概要を図5に示す。携帯電話端末上で動作する PCN クライアントは、加速度センサと電子コンパスの計測値から推定した歩数・移動方向と、ユーザの身長から概算した歩幅をもとに1歩ごとの移動量(ステップベクトル)を推定する。また、クライアントは Bluetooth のデバイス検出機能を用いて、近隣クライアントからの RSS を収集する。ステップベクトルおよび RSS は、3G/Wi-Fi ネットワークを経由して定期的に PCN サーバへ送信され、サーバ上で推定されたユーザ群の位置関係をクライアントへフィードバックすることで、リアルタイムなソーシャルナビゲーションを実現する。

前節で示した通り、PDR による推定軌跡には一般に大きな誤差が含まれる。そこで、PCN では、ステップベクトルおよび RSS による近接センシングをもとに、一定の期間にわたって類似した移動をするクライアント群(以下、グループ)を検出し、グループ内の移動軌跡の時間的・空間的な類似性を利用してセンサノイズ等に起因する誤差を補正する。さらに、“正面を横切る3人組”といったグループ行動コンテキストを、図6のように近隣ユーザ群の認識に活用することで、位置誤差がナビゲーションに与える影響を軽減する。

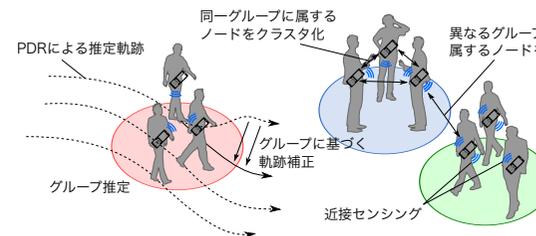


図5 PCN システムの概要



図6 PCN クライアントのプロトタイプ

4. 提案手法

PCN クライアントの集合を S とする。各クライアント $A_i \in S$ はステップベクトルの系列 $\langle s_1, s_2, \dots, s_m \rangle$ と Bluetooth RSS の観測結果を定期的に PCN サーバへ送信する。ここで、時刻 t において、 A_i が過去 τ 秒間に観測したステップベクトルの総和 $\sum_{k=1}^m s_k$ を、 A_i の時刻 t における **移動ベクトル** と定義し、 $u_{i,t}$ と表す。また、時刻 $(t - \tau, t]$ においてクライアント A_i, A_j 間で観測された RSS を $r_{ij,t}$ と表す。

4.1 Bluetooth による近接センシング

PCN クライアントは Bluetooth のデバイス検出(スキャン)機能を利用して、近隣クライアントからの RSS を定期的に収集する。この方法は、リンク確立を行うことなく端末間の RSS を収集できるという利点があるが、モバイル端末の位置推定に利用する場合には2つの課題がある。まず、周波数を高速で切り替えながら通信を行う Bluetooth の特性上、複数の端末が同時にスキャンを実行した場合には互いの検出率が著しく低下する。このため、各端末が連続的にスキャンを実行すると、RSS の収集率が極端に低くなる⁹⁾。さらに、スキャンには通常10秒以上の時間を要するため、RSS の取得頻度が厳しく制限される。

そこで、我々の実装では、スキャンを5秒間で中断するという方法をとっている。Bluetooth のデバイス検出機能は、無線範囲内にあるすべての端末を確実に検出できるように設計されているが、近接センシングでは、マルチパス伝搬や干渉による通信エラーが発生しやすい遠距離の端末を確実に検出するよりも、短時間で検出できる近隣端末からの RSS を可能な限り高速に収集することが望ましい。予備実験により、端末間距離が5m以内の場合、スキャン中断によるデバイス検出率の低下は10%未満であることを確認している。

また、スキャンの同時実行による検出率の低下を防ぐため、各クライアントはスキャン

の実行タイミングを確率的に決定する。クライアントは確率 p_{scan} でスキャンを開始し、 $(1-p_{scan})$ の確率で、一定期間待機する。 p_{scan} は経験的に 0.5 とし、待機時間は 2.5 秒～7.5 秒の範囲からランダムに決定する。

4.2 グループ行動コンテキストの検出

PCN サーバは、クライアントから収集した Bluetooth RSS および移動ベクトルの過去一定期間の履歴をもとに、ユーザ群のグループ行動を検出する。以降、時刻 t における、クライアント A_i の RSS の観測履歴を $R_i(t) = \{r_{ij,t'} | A_j \in S (i \neq j), t' = t - k\tau (k = 0, 1, \dots, N-1)\}$ 、移動ベクトルの履歴を $U_i(t) = \{\mathbf{u}_{i,t'} | t' = t - k\tau (k = 0, 1, \dots, N-1)\}$ と表す。本稿では、単位時間 τ を 2.0 秒、ウィンドウサイズ N を 30 とする。

提案手法では、ユーザ間の行動の類似度を、次の 2 つの指標に基づき定量化する。

(i) **近接性:** 同一グループに属するユーザは過去一定の期間にわたって互いに近くにいと仮定し、その度合をクライアント A_i, A_j 間で過去 $N\tau$ 秒間に閾値 Θ_{prox} 以上の RSS が観測された回数 n_{ij} により評価する (式 (1))。

$$n_{ij}(t) = \left| \{r_{ij,t'} | r_{ij,t'} \geq \Theta_{prox}, t' = t - k\tau (k = 0, 1, \dots, N-1)\} \right| \quad (1)$$

(ii) **軌跡類似性:** 同一グループに属するユーザは、過去一定期間の移動特性が時間的・空間的に類似すると仮定し、移動軌跡間の編集距離¹³⁾ によって類似度を評価する。一般に、2 つの系列 A, B の編集距離 $ED(A, B)$ は、 A を B に変換するために必要な最小の挿入、削除、置換操作の回数によって定義される。PCN では、移動ベクトル \mathbf{u}, \mathbf{v} が $\|\mathbf{u}\| - \|\mathbf{v}\| < \Theta_l$ 、 $|\arg(\mathbf{u}) - \arg(\mathbf{v})| < \Theta_\theta$ を共に満たすとき、これらが一致していると判定する。 Θ_l と Θ_θ はそれぞれ、ベクトル長と偏角に関するマッチングの閾値である。このもとで、2 つの移動ベクトルの系列 U, V の編集距離 $ED(U, V)$ を次の再帰式により定義する。

$$ED(U, V) = \begin{cases} n & \text{if } m = 0 \\ m & \text{if } n = 0 \\ \min\{ED(Rest(U), Rest(V)) + c, ED(Rest(U), V) + w, ED(U, Rest(V)) + w\} & \text{otherwise} \end{cases} \quad (2)$$

n, m は U, V に含まれる移動ベクトルの数、 $Rest(U)$ は U から先頭要素を取り除いた系列を表す。 c は U, V の先頭要素が一致しているとき 0、そうでないとき 1 となる関数であり、置換操作のペナルティを表す。一方、挿入・削除操作は、移動ベクトルの時刻をシフトすることに相当する。 w は挿入・削除操作のペナルティであり、本稿では $w = 0.5$ とする。このように、置換に比べて挿入・削除のペナルティを小さくすることで、グループ内のユー

ザ間の行動のタイムラグが軌跡類似性の評価値に与える影響を軽減している。

提案手法では、2 つの移動ベクトルの系列 $U_i(t), U_j(t)$ 間の距離 $d_{ij}(t)$ を次式で定義する。

$$d_{ij}(t) = ED(U_i(t), U_j(t)) \quad (3)$$

PCN では、近接性と軌跡類似性が共に満たされるとき、それらのクライアントが互いに同一の行動グループに属していると判断する。ここで、クライアントのペア $A_i, A_j (i \neq j)$ が同一の行動グループに属しているかどうかを確率変数 G_{ij} で表し、 A_i と A_j が同一のグループに属しているとき $G_{ij} = 1$ 、異なるグループに属しているとき $G_{ij} = 0$ とする。また、特に指定しない限り、 $n_{ij}(t), d_{ij}(t)$ をそれぞれ n_{ij}, d_{ij} と略記する。

ベイズの定理より、 n_{ij} と d_{ij} が与えられたときの G_{ij} の分布 $P(G_{ij} | n_{ij}, d_{ij})$ は、

$$P(G_{ij} | n_{ij}, d_{ij}) = \frac{P(n_{ij}, d_{ij} | G_{ij}) \cdot P(G_{ij})}{\sum_{G_{ij}=0}^1 P(n_{ij}, d_{ij} | G_{ij}) \cdot P(G_{ij})} \quad (4)$$

のように表せる。簡単のため、 n_{ij} と d_{ij} が G_{ij} のもとで独立であると仮定すると、

$$P(n_{ij}, d_{ij} | G_{ij}) = P(n_{ij} | G_{ij}) \cdot P(d_{ij} | G_{ij}) \quad (5)$$

さらに、 A_i と A_j が同一行動グループに属しているかどうかに関する事前情報がないとすると、 $P(G_{ij} = 0) = P(G_{ij} = 1) = 0.5$ となり、式 (4) は次のように簡単化できる。

$$P(G_{ij} | n_{ij}, d_{ij}) = \frac{P(n_{ij} | G_{ij}) \cdot P(d_{ij} | G_{ij})}{\sum_{G_{ij}=0}^1 P(n_{ij} | G_{ij}) \cdot P(d_{ij} | G_{ij})} \quad (6)$$

$P(n_{ij} | G_{ij}), P(d_{ij} | G_{ij})$ は、それぞれ、クライアント A_i, A_j が同一グループに属しているかどうかと与えられた場合の n_{ij}, d_{ij} の分布であり、事前学習により取得する。

グループ推定を行うためには、まず、すべてのクライアントのペア A_i, A_j について、RSS および移動ベクトルの履歴から n_{ij}, d_{ij} を算出する。次に、式 (6) のグループ推定モデルに従って、これらのクライアントが同一のグループに属している確率 (**グループ尤度**) $P(G_{ij} = 1 | n_{ij}, d_{ij})$ を求める。最後に、次のようなグループ化グラフ $G_s = \langle V, E \rangle$ を構成し、クライアントのグループを検出する。グループ化グラフは各クライアントに対応する頂点を持ち ($V = S$)、グループ尤度が閾値 Θ_{group} よりも大きいクライアント間に辺が引かれる ($E = \{ \langle A_i, A_j \rangle | P(G_{ij} = 1 | n_{ij}, d_{ij}) > \Theta_{group} \}$)。PCN は G_s の連結成分を 1 つの行動グループと推定する。なお、本稿では $\Theta_{group} = 0.5$ とする。

4.3 グループ行動コンテキストに基づく相対位置推定

移動軌跡の補正: グループ行動コンテキストに基づく推定軌跡の補正を行うため、PCN では

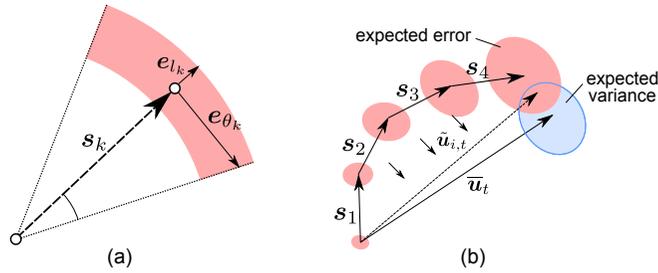


図7 ステップレベルの誤差モデルに基づく移動ベクトルの補正

まず、移動ベクトルの誤差を予測する。PDRによる軌跡推定の誤差要因としては、主として i) ステップ時の歩幅の推定誤差, ii) ステップ時の移動方向の推定誤差, および iii) ステップの誤検出/検出漏れによる誤差の3つが考えられる。このうち i) と ii) はステップ毎に発生し、移動ベクトルに蓄積される誤差である。i) によって生じる位置誤差を e_{l_k} , ii) に起因する位置誤差を e_{θ_k} とすると、ステップ s_k において新たに蓄積される誤差は $e_k = e_{l_k} + e_{\theta_k}$ と表せる。 e_{l_k} と e_{θ_k} の分布は、図7 (a) に示すように、ステップベクトル s_k に依存して決まる。 e_{l_k} は s_k と同じ向きとし、長さは正規分布 $\mathcal{N}(0, \sigma_l^2)$ に従うとする。また、方位誤差 $\Delta\theta$ は正規分布 $\mathcal{N}(0, \sigma_\theta^2)$ に従うとし、 e_{θ_k} は、 s_k と直交する長さ $\|s_k\| \cdot \Delta\theta$ のベクトルで近似する。本稿では、予備実験の結果に基づき、 $\sigma_l = 0.5$ m, $\sigma_\theta = 30^\circ$ とする。

一方、iii) による位置誤差 e_0 は、過去 τ 秒間の移動に非依存な誤差である。提案手法では、 e_0 の分布を $P(e_0) = \mathcal{N}(\mathbf{0}, \sigma_0^2 \mathbf{I})$ のように正規分布でモデル化する。ここで、 σ_0 はステップ検出の精度に依存するパラメータ、 \mathbf{I} は2次元の単位行列である。なお、本稿では、経験的に $\sigma_0 = 1.0$ m とする。

次に、上記のステップレベルの誤差予測モデルに基づき、移動ベクトルの誤差分布を算出する。ここで、 k 歩目までのステップベクトルの総和を u'_k と表す。ステップの誤検出/検出漏れに起因する誤差 e_0 は過去 τ 秒間のステップ数に依存しないため、 e_0 の分布を0ステップ目の誤差分布 $P(u'_0)$ と定義する(式(7))。

$$P(u'_0) = P(e_0) \quad (7)$$

以降、上記の誤差分布をステップごとに逐次的に更新することにより、移動ベクトルの誤差分布を求める。 u'_{k-1} と u'_k との関係は、

$$u'_k = u'_{k-1} + s_k + e_k \quad (8)$$

となる。この漸化式より、 k ステップ目の誤差分布 $P(u'_k | s_{1:k})$ は、 $k-1$ ステップ目の誤

差分布 $P(u'_{k-1} | s_{1:k-1})$ とステップレベルの誤差予測モデル $P(e_k | s_k)$ を用いて次のように表される。

$$P(u'_k | s_{1:k}) = \int \left\{ \int P(u'_k | s_k, e_k, u'_{k-1}) \cdot P(u'_{k-1} | s_{1:k-1}) du'_{k-1} \right\} \cdot P(e_k | s_k) de_k \quad (9)$$

ここで、 $P(u'_{k-1} | s_{1:k-1})$ から N_p 個の点 $u'^{(j)}$ ($j = 1, 2, \dots, N_p$) をサンプリングし、それら N_p 個の粒子によって $P(u'_{k-1} | s_{1:k-1})$ をモンテカルロ近似する(式(10))。

$$P(u'_{k-1} | s_{1:k-1}) \simeq \frac{1}{N_p} \sum_{j=1}^{N_p} \delta(u'_{k-1} - u'^{(j)}) \quad (10)$$

上記のモンテカルロ表現を用いると、式(9)の更新式は次のように書き換えられる。

$$P(u'_k | s_{1:k}) = \frac{1}{N_p} \sum_{j=1}^{N_p} \left[\int P(u'_k | s_k, e_k, u'^{(j)}) \cdot P(e_k | s_k) de_k \right] \quad (11)$$

さらに、各粒子 $u'^{(j)}$ に対して、誤差分布 $P(e_k | s_k)$ から1つずつ誤差のサンプル値 $e_k^{(j)}$ を生成し、 $P(e_k | s_k)$ を次のように近似する。

$$P(e_k | s_k) \simeq \delta(e_k - e_k^{(j)}) \quad (12)$$

粒子の数は N_p 個であるため、全体としては N_p 個のノイズサンプルが抽出され、 $P(e_k | s_k)$ を十分に近似することができる。上記の近似を用いると、式(11)は次式のように表せる。

$$\begin{aligned} P(u'_k | s_{1:k}) &\simeq \frac{1}{N_p} \sum_{j=1}^{N_p} \left[\int P(u'_k | s_k, e_k, u'^{(j)}) \cdot \delta(e_k - e_k^{(j)}) de_k \right] \\ &= \frac{1}{N_p} \sum_{j=1}^{N_p} \left[\delta(u'_k - (u'^{(j)} + s_k + e_k^{(j)})) \right] \end{aligned} \quad (13)$$

以上の議論に基づき、PCNでは移動ベクトルの誤差を次のように予測する。まず、式(7)で定義される初期分布 $P(u'_0)$ から N_p 個の粒子 $u'^{(j)}$ ($j = 1, 2, \dots, N_p$) を生成する。次に、それぞれの粒子 $u'^{(j)}$ に対して、ステップベクトル s_k およびステップレベルの誤差予測モデル $P(e_k | s_k)$ から生成した誤差のサンプル $e_k^{(j)}$ を加える。これをすべてのステップに対して逐次的に行うことで、移動ベクトルの誤差分布 $P(u_{i,t}) = P(u'_m | s_{1:m})$ が得られる。

提案手法では、グループ内の軌跡のバラつきを事前学習に基づきモデル化し、各クライアント A_i の移動ベクトルを、図7 (b) のように予測誤差の範囲内で補正する。バラつき

のモデルでは、 A_i の移動ベクトル $\mathbf{u}_{i,t}$ と、 A_i が属するグループ $G = \{A_1, A_2, \dots, A_n\}$ の平均移動ベクトル $\bar{\mathbf{u}}_t = \frac{1}{|G|} \sum_{A_j \in G} \mathbf{u}_{j,t}$ の長さの比 $\min\left(\frac{\|\mathbf{u}_{i,t}\|}{\|\bar{\mathbf{u}}_t\|}, \frac{\|\bar{\mathbf{u}}_t\|}{\|\mathbf{u}_{i,t}\|}\right)$ が正規分布 $\mathcal{N}(0, \sigma_{g_l}^2)$ 、移動方向の差 $|\arg(\mathbf{u}_{i,t}) - \arg(\bar{\mathbf{u}}_t)|$ が正規分布 $\mathcal{N}(0, \sigma_{g_\theta}^2)$ に従うとする。本稿では、予備実験の結果に基づき、 $\sigma_{g_l} = 0.5$ m, $\sigma_{g_\theta} = 30.0^\circ$ とする。このもとで、それぞれの粒子 $\mathbf{u}_k^{(j)}$ を移動モデルに基づく事前分布 $P(\mathbf{u}_{i,t}^{(j)}|\bar{\mathbf{u}}_t)$ によって重み付けし、式 (14) により期待値ベクトル $\tilde{\mathbf{u}}_{i,t}$ を算出する。PCN では、 $\tilde{\mathbf{u}}_{i,t}$ を補正後の移動ベクトルとする。

$$\tilde{\mathbf{u}}_{i,t} = E[\mathbf{u}_{i,t}|\bar{\mathbf{u}}_t] = \sum_{j=1}^{N_p} \mathbf{u}_{i,t}^{(j)} \cdot \frac{P(\bar{\mathbf{u}}_t|\mathbf{u}_{i,t}^{(j)})}{\sum_{k=1}^{N_p} P(\bar{\mathbf{u}}_t|\mathbf{u}_{i,t}^{(k)})} \quad (14)$$

RSS に基づく軌跡マッピング: 次に、補正された移動ベクトルと RSS の履歴に基づき、バネモデルによってクライアント間の相対的な位置関係を決定する。初期状態においてはクライアント間の位置関係は未知であるため、仮想的な座標系にクライアントを無作為に配置し、推定を開始する。Wi-Fi 測位等によって各クライアントの大きな位置を取得できる場合には、それらを推定位置の初期解として用いることも可能である。各クライアント A_i の推定位置は、 τ 秒ごとに、次のような2段階のプロセスで更新される。i) 前時刻の推定位置 $\mathbf{p}_{i,t-1}$ に現時刻の移動ベクトル $\tilde{\mathbf{u}}_{i,t}$ を加えることで、推定位置の初期解 $\mathbf{p}_{i,t}^{(0)}$ を求める。ii) 下記の反復アルゴリズムによって、RSS に基づきクライアント間の位置関係を修正する。

各イテレーション k において、過去 τ 秒間に Θ_{prox} 以上の RSS が観測されたすべてのクライアントの組 (A_i, A_j) の間に、次式で定義される仮想的な引力を仮定する。

$$\mathbf{f}_{ij,t}^{(k)} = \begin{cases} \kappa \cdot \max\left(0, \|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\| - d_p\right) \cdot \frac{\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}}{\|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\|} & \text{if } r_{ij,t} > \Theta_{prox} \\ \mathbf{0} & \text{otherwise} \end{cases} \quad (15)$$

$\mathbf{p}_{i,t}^{(k-1)}$, $\mathbf{p}_{j,t}^{(k-1)}$ はイテレーション $k-1$ における A_i , A_j の推定位置である。 κ は引力の強さを表す係数であり、パラメータとして与える。また、 d_p は Θ_{prox} 以上の RSS が観測される最大のクライアント間距離であり、本稿では、予備実験に基づき $d_p = 6.0$ m とする。

3章で述べた通り、RSS をもとにクライアント間の距離を推定することは難しく、高い信頼度で得られる情報はクライアントが距離 d_p 以内にあるかどうかのみである。限られた測定精度のもとでより粒度の細かい位置推定を実現するため、PCN では、グループ内の近接性を活用したヒューリスティックを取り入れる。具体的には、同一のグループに属していると推定されたクライアント間の引力を算出する際、 Θ_{prox} 以上の RSS が観測された場合のクライアント間の想定距離 d_p を、より小さな値 d'_p で置き換えることにより、グループ

メンバ同士をより近くに配置する。なお、本稿では $d'_p = 3.0$ m とする。

また、心理学の分野では、人間は互いに近くにあるものをグループと認識することが知られている¹⁴⁾。そこで PCN では、次式のように、同一のグループに属するクライアントの間に微小な引力を加える一方、異なるグループのクライアント間には微小な斥力を働かせることにより、推定位置がグループごとに空間的に分離されるように、各クライアントの推定位置に微小な調整を加える。

$$\mathbf{f}'_{ij,t}{}^{(k)} = \begin{cases} \kappa' \cdot \max\left(0, \|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\| - d_{p'}\right) \cdot \frac{\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}}{\|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\|} & \text{if } G_{ij} = 1 \\ -\kappa' \cdot \max\left(0, d_{p'} - \|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\|\right) \cdot \frac{\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}}{\|\mathbf{p}_{j,t}^{(k-1)} - \mathbf{p}_{i,t}^{(k-1)}\|} & \text{otherwise} \end{cases} \quad (16)$$

係数 κ' はパラメータであり、 $\kappa' \ll \kappa$ とすることで、RSS と推定位置との整合性を保つ。

次に、クライアント A_i にかかる合力に応じて、イテレーション k における推定位置の更新ベクトルを以下のように決定する。ダンピング係数 α はパラメータとして与える。

$$\mathbf{v}_i^{(k)} = \alpha \left(\mathbf{v}_i^{(k-1)} + \sum_{A_j \in S \setminus \{A_i\}} \left(\mathbf{f}_{ij,t}^{(k)} + \mathbf{f}'_{ij,t}{}^{(k)} \right) \right) \quad (17)$$

上記の更新ベクトルをもとに、次式により A_i の推定位置を更新する。

$$\mathbf{p}_{i,t}^{(k)} = \mathbf{p}_{i,t}^{(k-1)} + \mathbf{v}_i^{(k)} \quad (18)$$

以上の操作を、すべてのクライアント $A_i \in S$ に対して、位置の修正回数がからかじめ定めた上限 N_{term} に達するか、すべてクライアントにかかる力の総和が閾値 f_{term} 以下になるまで逐次的に繰り返すことで、現時刻 t におけるクライアント間の位置関係が求まる。

5. 性能評価

実環境におけるセンサ/通信ログを取得するため、2011年8月に大阪で開催された産学連携イベント Knowledge Capital Trial 2011 (<http://www.kmo-jp.com/>) の見本市会場にて、Google Nexus S を用いたフィールド実験を行った。見本市では、図8のような27m × 40mの会場において、16の大学・企業が展示ブースを出展し、延べ数千人が来場した。実験では、20名の被験者がそれぞれ端末を保持し、展示ブースを4人ずつのグループで巡回した。端末上ではPDRおよび近接センシングを実装した実験用アプリケーションを動作させ、移動軌跡およびRSSのログを取得した。各グループは、会場入口(図8のA地点)から同時に会場内へ入り、約30分間で6~12箇所の展示ブースを巡回した後、会場出

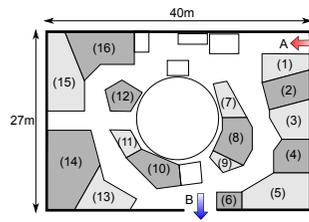


図 8 フロアマップ

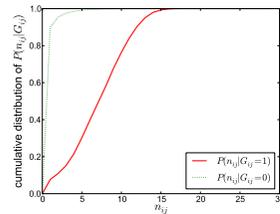


図 9 n_{ij} の分布

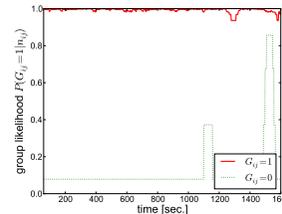


図 10 グループ尤度 (近接性)

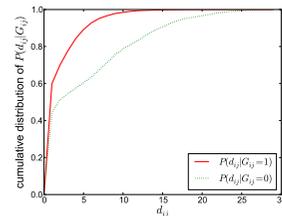


図 11 軌跡類似性の分布

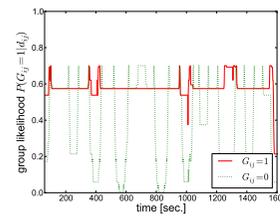


図 12 グループ尤度 (軌跡類似性)

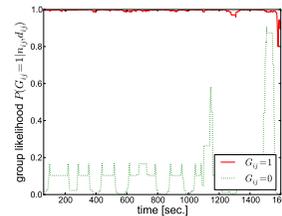


図 13 グループ尤度 (統合後)

口 (同図 B 地点) へ向かう。各被験者はスタート地点で PCN アプリケーションを起動するものとし、クライアントの初期位置は既知とする。以上の実験を 3 セット行うことにより、延べ約 1,800 分間 (90 min. × 20 名) のログを取得した。以降の性能評価では、3 回の実験データのうち 2 回分をグループ推定モデルを構築するための学習用データ、残りの 1 回分をテスト用データとして利用した。

5.1 グループ推定モデルの構築

はじめに、RSS に基づく近接性のモデルと、推定移動軌跡に基づく軌跡類似性のモデルをそれぞれ構築し、これら 2 つのモデルを統合することで、グループ推定モデルを構成する。**近接性モデル:** まず、学習用データから近接性の指標となる n_{ij} (式 (1)) を算出し、その分布を求めた。図 9 は、同一グループに属するクライアント間 ($G_{ij} = 1$) および異なるグループに属するクライアント間 ($G_{ij} = 0$) における n_{ij} の分布を表している。 $G_{ij} = 0$ の場合には 90% 以上の確率で $n_{ij} \leq 1$ となっているのに対し、 $G_{ij} = 1$ の場合には 95% 以上が $n_{ij} \geq 2$ となっており、グループ間で有意な差が見られる。上記の近接性モデルを単独で利用し、テスト用データ上で、あるクライアント A_i と、同一グループのクライアント A_j 、異なるグループのクライアント $A_{j'}$ とのグループ尤度を算出した結果を図 10 に示す。 A_j とのグループ尤度がほぼ 1 に近い値で推移しているのに対し、 $A_{j'}$ とのグループ尤度は

0.1 未満の低い値となっている。 $A_{j'}$ とのグループ尤度が $t = 1, 100$ 秒および $t = 1, 500$ 秒付近において一時的に大きくなっているのは、 A_i と $A_{j'}$ が互いに近くのブースを巡回していたためである。

軌跡類似性モデル: 次に、学習用データから、移動軌跡の編集距離 d_{ij} の分布を算出した。学習の結果得られた分布を図 11 に示す。見本市という実験環境の特性上、ユーザが各ブースを見学するために立ち止まっている時間の割合が比較的長く、 $G_{ij} = 0$ の場合にも d_{ij} が 0 となる時間の割合が高くなっている。一方、 d_{ij} が 5 以上となる確率は、 $G_{ij} = 1$ の場合には約 10% であるのに対し、 $G_{ij} = 0$ では 40% 以上となっており、ブース間の移動中には、グループ間で移動軌跡に大きな差が生じていることがわかる。構築した軌跡類似性モデルを単独で用いて、前述の A_i と A_j 、 $A_{j'}$ とのグループ尤度を算出した結果を図 12 に示す。双方のユーザがブースで立ち止まっているときには、軌跡間の編集距離が 0 となるため、グループの一致性によらず、グループ尤度が高くなっている。一方、いずれかユーザが移動している時には、異なるグループに属する $A_{j'}$ とのグループ尤度が大きく低下していることが確認できる。

グループ推定モデル: 最後に、近接性モデルと軌跡類似性モデルを式 (6) により統合することで、グループ推定モデルを構成する。構築したモデルに基づき、前述の A_i と A_j 、 $A_{j'}$ のグループ尤度を算出した結果を図 13 に示す。前述の通り、グループ同士が互いに近くにいる場合には、 $G_{ij} = 0$ の場合にも近接性に基づくグループ尤度 (図 10) が高くなるが、グループ間の移動の振る舞いの差が軌跡類似度を押し下げることにより、統合後の尤度は低く抑えられている。このように、提案手法では、近接性モデルと軌跡類似性モデルが補完し合うことにより、グループ推定の精度を高める。

5.2 性能評価結果

グループ推定精度: 構築したモデルを用いてグループ推定を行い、すべてのクライアントのペアについて、それらが同一のグループに属しているかどうかを正しいグループ情報と照合したときの正解率 (グループ推定精度) を評価した。その結果を図 14 に示す。全時刻における平均正解率は 94.8% となり、高い精度でユーザ群のグループ行動を検出できることが分かった。 $t = 1, 400$ 秒付近における精度の一時的な低下は、複数のグループが互いに近くのブースで立ち止まったことにより、それらが 1 つのグループと誤認識されたことによるものである。ウィンドウサイズ N を大きくし、過去の近接性と移動軌跡の履歴を考慮すれば、一時的に類似した振る舞いをしたグループ同士を分離することが可能となるが、 N を大きくすると、ユーザの合流や離脱によるグループの変化への追従性が低下するため、モビ

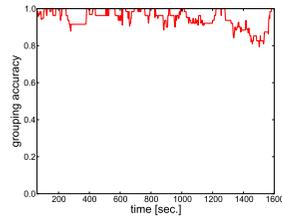


図 14 グループ推定精度

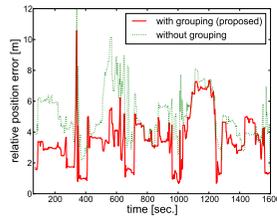


図 15 相対位置誤差

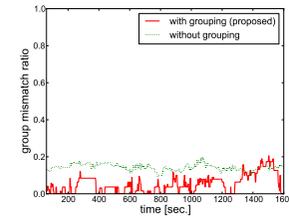


図 16 グループとクラスタの不一致率

リティやグループの流動性に応じて適切にパラメータを設定することが望ましい。

位置推定精度: 提案手法の位置推定精度を、各クライアントから半径 10m 以内にいるユーザ群との相対位置誤差によって評価した。提案手法の相対位置誤差を、グループ情報に基づく補正を行わず、PDR による移動軌跡と RSS に基づく近接センシングのみを用いて位置推定を行った場合と比較した結果を図 15 に示す。グループ情報に基づく補正によって、提案手法では、ほぼすべての時刻において位置推定精度が改善されている。全シミュレーション時間の平均誤差は、グループ情報に基づく補正を行わない場合 5.11m であるのに対し、提案手法では 3.51m となり、位置推定精度を 31.3% 改善できることが分かった。

位置の認識性: 人間の知覚には、近くにあるもの同士をグループと認識する性質がある¹⁴⁾。そこで、位置推定結果に群平均法によるクラスタリングを適用し、推定位置のクラスタと行動グループとの一致性から、推定位置の認識性を評価した。まず、各クライアントの推定位置を要素とするサイズ 1 のクラスタを形成し、すべてのクラスタのペアについて、要素間の平均距離 (クラスタ間距離) を算出する。その後、最小クラスタ間距離が閾値以下になるまで、クラスタ間距離が最小となる 2 つのクラスタを繰り返しマージすることにより、クラスタリングが完了する。本稿では、最小クラスタ間距離の閾値を経験的に 1.5m とした。以上のクラスタリング結果をもとに、クライアントのペアが同一のクラスタに属しているかどうかを正しいグループ情報と照合し、不一致率を評価した結果を図 16 に示す。グループ推定による補正を行わない場合には、位置誤差の影響によって平均 14.3% の割合でグループとクラスタの不一致が発生しているのに対し、提案手法の平均不一致率は 5.1% となり、位置関係の認識性を改善できることが分かった。

6. まとめ

本稿では、周囲の人々との位置関係を直感的に認識するためのソーシャルナビゲーション

手法を提案した。提案手法は、ユーザ群のグループ行動を検出し、グループ内における移動軌跡の類似性や近接性を利用して位置誤差を補正することで、位置情報の認識性を高める。フィールド実験の結果、ユーザ群のグループを 94.8% の精度で検出するとともに、グループ情報に基づく位置補正により、位置推定精度を 31.3% 改善できることを示した。

参考文献

- 1) foursquare Labs Inc.: foursquare, <https://foursquare.com/>.
- 2) Do, T. M.T. and Gatica-Perez, D.: GroupUs: Smartphone Proximity Data and Human Interaction Type Mining, *Proc. of ISWC '11*, pp.21–28 (2011).
- 3) Vu, L., Do, Q. and Nahrstedt, K.: Jyotish: A Novel Framework for Constructing Predictive Model of People Movement from Joint Wifi/Bluetooth Trace, *Proc. of PerCom '10*, pp.54–62 (2010).
- 4) Yin, J., Yang, Q. and Ni, L.M.: Learning adaptive temporal radio maps for signal-strength-based location estimation, *IEEE Transactions on Mobile Computing*, Vol.7, No.7, pp.869–883 (2008).
- 5) Harter, A., Hopper, A., Steggles, P., Ward, A. and Webster, P.: The Anatomy of a Context-Aware Application, *Proc. of MobiCom '99*, pp.59–68 (1999).
- 6) Priyantha, N., Chakraborty, A. and Balakrishnan, H.: The cricket location-support system, *Proc. of MobiCom '00*, pp.32–43 (2000).
- 7) Higuchi, T., Fujii, S., Yamaguchi, H. and Higashino, T.: An Efficient Localization Algorithm Focusing on Stop-and-Go Behavior of Mobile Nodes, *Proc. of PerCom '11*, pp.205–212 (2011).
- 8) Peng, C., Shen, G., Zhang, Y., Li, Y. and Tan, K.: BeepBeep: A High Accuracy Acoustic Ranging System using COTS Mobile Devices, *Proc. of SenSys '07*, pp. 1–14 (2007).
- 9) Banerjee, N., Agarwal, S., Bahl, P., Chandra, R., Wolman, A. and Corner, M.: Virtual Compass: relative positioning to sense mobile social interactions, *Proc. of Pervasive '10*, pp.1–21 (2010).
- 10) Steinhoff, U. and Schiele, B.: Dead Reckoning from the Pocket — An Experimental Study, *Proc. of PerCom '10*, pp.162–170 (2010).
- 11) Constandache, I., Choudhury, R.R. and Rhee, I.: Towards Mobile Phone Localization without War-Driving, *Proc. of INFOCOM '10*, pp.1–9 (2010).
- 12) Constandache, I., Bao, X., Azizyan, M. and Choudhury, R.R.: Did you see Bob?: human localization using mobile phones, *Proc. of MobiCom '10*, pp.149–160 (2010).
- 13) Chen, L., Özsu, M.T. and Oria, V.: Robust and Fast Similarity Search for Moving Object Trajectories, *Proc. of SIGMOD '05* (2005).
- 14) Wertheimer, M.: *Laws of organization in perceptual forms* (1938).