

位置情報を用いた実空間における人間関係分析手法の提案

石塚 宏紀¹ 小林 直¹ 村松 茂樹¹ 小林 亜令¹ 小野 智弘¹

概要：近年、ソーシャルメディアの発展に伴って個々人の関係性に関する情報を活用した人間関係分析に関する研究が盛んに行われてきた。また、仮想世界上でのコミュニケーションのみならず、実空間における人間関係の研究においても位置情報等を用いたにおける関係性抽出手法が提案されている。分析された人間関係データは、広告配信等のマーケティング最適化や組織におけるコミュニケーションの活性化、関係性改善に向けた行動変容などへの活用が期待されている。本論では、位置情報を用いた実空間における人間関係分析技術において、移動中及び滞在中の同時移動行動を同時に加味したモデルを提案し、2者間の行動に対して、同時行動、行動共有シーン、行動共有パターンの3軸による特徴量を用いた学習を行った。提案手法の評価において、約1ヶ月半にわたる98名のスマートフォンによるGPS履歴と被験者間の人間関係に関する正解データを収集し、機械学習及びルールベースによる2種類の分類器を生成し、関係性有無を推定した。評価結果では、Accuracyで0.9程度得ることが分かった。尚、実験にて得られたデータについて、本研究の目的において被験者間の関係性の詳細分析や外部発表について明確な個別許諾を被験者からいただいた上で研究を行なっています。

1. はじめに

個々人の関係性に関する情報がWebコンテンツ[1]やソーシャルネットワーク[2]を通して発信されたことにより、仮想世界上の情報に基づいた人間関係分析に関わる研究が盛んに行われてきた。一方で、ユビキタスコンピューティング技術の発展に伴い、実空間における人間関係の研究においてもRFIDやBluetooth通信などを用いて、学会会場や学内など限定的なエリアにおける関係性抽出手法が提案されている。人々の関係性分析技術は、広告配信等のマーケティング最適化や関係性改善による生活環境向上にむけた行動変容への活用が期待されている。

さらに、近年、位置情報付きソーシャルネットワークから得られるユーザの行動情報を活用した実空間における人間関係分析についても研究が盛んになってきている。既存研究における基本的な概念は、ユーザ間の近接性を関係性を現す指標として用いるということである。近接性においては、全行動軌跡を通した近接性とソーシャルチェックインなどのサービスを活用した滞在時における近接性が活用されている。本論では、ソーシャルチェックイン情報を活用した既存研究では活用しきれなかった移動中における同時行動も加味した関係性推定モデルを提案するとともに、2者間の行動に対して、同時行動、行動共有シーン、行動共

有パターンの3軸による特徴量を用いた学習を行った。提案手法は、位置情報を用いた実空間における関係性推定を行うための候補ペアを抽出し、その後、候補ペアに対して、関係性有無を推定するための特徴量を算出する。提案手法の評価にあたり、我々は、提案手法のプロトタイプを実装し、また、約1ヶ月半にわたる98名のスマートフォンによるGPS履歴と被験者間の人間関係に関する正解データを収集し、機械学習及びルールベースによる2種類の分類器を生成し、関係性有無を推定した。尚、本研究にて収集したデータについて、本研究の目的において被験者間の関係性の詳細分析や外部発表について明確な個別許諾を被験者からいただいた上で研究を行なっています。収集したデータを用いて我々は、Random Forestによる分類器と集計値に基づくルールベース分類器を作成し、それぞれにおいて関係性有無の推定精度を評価した。評価結果において、機械学習による分類器とルールベース分類器に大きな精度の違いはないが、ルールベースにおいてPrecisionを上げるパラメータ設定を見出した。結果、Accuracyで0.9程度得ることが分かった。

本稿は、2章にて本分野における関連研究の動向と本論の貢献についてまとめた上で、3章にて提案手法の基本設計やリンク特徴量計算手法について述べる。4章にて正解データ収集実験の概要と収集データの詳細について言及し、5章にて正解データを用いた分類器生成及び、人間関係有無の推定精度について考察する。6章では、本分野に

¹ 株式会社 KDDI 研究所
KDDI R&D Laboratories Inc.

おけるモデル生成の在り方について議論を行ない、7章にてまとめと今後の課題について述べる。

2. 関連研究

本章では、実空間における人間関係分析手法の研究事例について述べて、本提案の貢献を明確化する。本分野における既存研究は、RFIDやBluetoothなど近距離無線技術を用いた近接性検知による限定的なコミュニティ内における関係性分析手法と位置情報連携したソーシャルネットワークサービス等によって得られた長期間にわたるユーザの行動情報を含む位置情報を用いた関係性分析手法に分類される。

2.1 限定的なコミュニティ内における人間関係分析

Waber等[3]は、Olguin等[4]が開発したマイクセンサと加速度センサ、赤外線センサ、Bluetooth送受信器を備えた *Sociometric Badges* を用いてオフィス内における人間関係やコミュニケーション量を評価する実験を行った。さらに、本実験では、オンライン上でのコミュニケーション手段として、メール送受信履歴を取得し、オンライン・オフラインの両面からコミュニケーションの振る舞いを分析している。脇坂等[5][6][7]が開発したオフィス向け人間関係収集アプリケーションであるビジネス顕微鏡は、日立製作所のオフィスを含めた様々なオフィス環境での実験がなされている。ビジネス顕微鏡は、組織内におけるコミュニケーションを定量的に分析可能なツールであり、個人が所持する名札型センサノードとオフィス環境に固定的に配置された赤外線ビーコンの2つ機器によって構成されている。名札型センサノードに内蔵された加速度センサによって、個人人の動きを測定し、環境に配備された赤外線センサによってコミュニケーションの質を測定している。辻等の研究[6]においては、デジタル顕微鏡のセンサデータを用いて、ある組織におけるコミュニケーションの質や量、1日の時間の使い方を可視化するビジネス顕微鏡ディスプレイをオフィスに導入することで従業員同士のオフィスにおける会話を誘発することに成功している。また、我々[8]もスマートフォンアプリを用いたコミュニティにおける人間関係分析手法を提案し、近距離無線による近接性を用いた限定コミュニティの抽出技術について提案をしている。これらの手法には、近接性検知のための専用機器もしくは、専用アプリケーションが必要となるため、こうした条件をユーザに強いることが可能なコミュニティでの活用に限定されてしまう。

2.2 位置情報を用いた人間関係分析

Li等[14]は、一連の位置情報系列から各ユーザの移動と滞在履歴に注目し、滞在地の集合を頻度によって階層グラフで表現し、各層において滞在地クラスターを定義してい

る。最小単位である下層のクラスター類似の高い2者間に関係性があると推定している。関係性の範囲をマイクロからマクロまで捉えられることから抽象度の異なる分析には適している。また、Zheng等[15]やXiao等[16]は、ユーザ間の行動軌跡の類似性に基づいた研究を行っている。しかしながら、これらの研究は実験期間における移動系列や滞在地の類似性に注目しているものの、ユーザ間の同時空間共有を捉えられていない。

次に、Eagle等[10]は、9ヶ月間にわたる94名の学生と教員からデータを収集している。彼らは、同被験者の携帯電話から得られた通信履歴や位置情報に関する行動ログと被験者自身による関係性に関するアンケートからなる2種のデータを用いて2者間の関係性を分析している。分析手法としては、アンケートによって得られた正解データも基いて、ユーザ間の位置情報による物理的な近接性、通信や通話履歴による仮想的な近接性を入力とした回帰分析によってモデルを生成している。関係性を分類する上で有効であった特徴は、同時空間共有であり、特に、業務時間や業務場所以外の状況での時空間共有が強力であることを示唆している。また、Crandall等[11]は、Flickerから得られた位置情報に基づいて友人関係を推定する確率モデルを提案している。彼らもEagle等と同様に同時空間共有が2者間の友人関係を推定するための重要な特徴量であると結論づけている。しかしながら、モデル生成の前提条件として、誰もが1人は友人がいることを規定しており、非現実的な条件であると思われる。また、同時空間の滞在は独立事象として捉えられており、滞在の頻度や連続性についても考慮されていない点が課題としてあげられる。

Cranshaw等[12]は、時空間データを利用した関係性や接続性分析における多種多様な特徴量を提案し、それらを用いて2項分類問題に対する判定器を生成している。実験の結果から、ユーザの移動パターンとソーシャルネットワーク上における友人の数に強い相関があることを示唆している。さらに、彼らは、チェックインされた場所の名前をTF-IDFによって重み付けし、各場所の特徴量を用いた分類を行っている。Chang等[13]も彼らと同様に機械学習による関係性予測を実施している。

一方で、Pham等[9]は、2者間の関係性における強度を定義するために、entropy-based model (EBM) を提案し、且つ人間関係と因果関係のない偶発的な時空間共有を関係性分析から除外するための仕組みを導入している。また、最新の研究事例として、Wang等[17]は、関係性及び強度の分析において、各位置における個人人の特性とグローバルな特性を考慮した分析を行っている。また、Zhang等[18]は、時空間共有に着目せずユーザ間の距離だけに注目してモデル化することで関係性と強度を定義している。




図 1 システム設計

2.3 本研究の貢献

本研究は、利用者の承諾を得た上で、広く普及したモバイル・アプリケーションによるバックグラウンドでの定期的な GPS 測位及び、収集基盤によって得られる膨大なユーザの位置情報 [19] を用いた人間関係分析を想定している。そのため、本機能を実現するための特殊な機器や専用アプリを必要としないため、分析対象のコミュニティは限定されない。一方で、既存の位置情報を用いた人間関係分析手法は、移動軌跡の類似性に着目した手法 [15][16] と滞在事象における同時空間共有に着目した手法 [9][17] が提案されている。しかしながら、滞在時のみに注目し、移動中における同時空間共有については考慮されていない。我々は、移動中においても同移動経路及び手段にて行動を共にする 2 者間の関係性は、関係性の有無及び強度を意味づける大きな特徴量であると仮説する。本論では、滞在時の時空間共有のみならず、移動中における同時空間共有も考慮した特徴量を用いて、人間関係の有無を推定する手法を提案する。以下に本論の貢献を明確化する。

- (1) 同時行動、行動共有シーン、行動共有パターン の 3 軸による位置情報による関係性推定の特徴量を定義
- (2) 同時滞在行动と同時移動行動の両面からの人間関係分析手法提案
- (3) 約 1 ケ月半による 98 名の継続的な GPS データと関係性に関するアンケート調査に基づいた実験と評価

3. 提案手法

我々の提案手法では、まず、位置情報を用いた実空間における関係性推定を行うための候補ペアを抽出し、その後、候補ペアに対して、関係性有無を推定するための特徴量を算出している。本章では、提案手法の概要を解説した後に、推定候補ペア抽出手法及び、候補ペア間における関係性有無推定の特徴量について詳細を述べる。

3.1 提案手法の基本設計

本論において、各ユーザ u が任意の規則に基いた時間 t

に取得した緯度経度情報を含む位置情報 l によって構成される時空間情報タプルは、 $\langle u, l, t \rangle$ として表現する。提案手法は、ユーザ集合 $U = (u_1, u_2, \dots, u_M)$ 及び、位置情報系列の集合 $L = (l_1, l_2, \dots, l_N)$ において、各ユーザの時空間情報タプル集合 $\langle u, l, t \rangle$ が入力として与えられた場合におけるユーザ間の関係性有無 $e_i = (u_i, u_j)$ の推定を行ない $E = (e_1, e_2, \dots, e_N)$ を得る。提案手法の基本設計を図 1 に示す。提案手法は、入力から出力に向けて移動滞在判定部、候補ペア抽出部、リンク特徴量算出部、リンク推定部の 4 つの機能から構成される。リンク推定部による最終的な出力は、ユーザ集合 U に対する関係性が表現された無向グラフ $G = (U, E)$ を得る。以下にて各部における処理詳細を述べる。

3.2 移動滞在判定部

各ユーザの同行動分析を行うための前処理として、位置情報系列を移動中と滞在中に分別する処理を実行する。GPS や WiFi に基づく位置情報履歴による移動滞在判定は、多数研究されており、[20][21][22] 等は、位置情報履歴のみを利用し、[23] 等は、位置情報履歴及び、取得時間情報を併用してクラスタリング手法により移動滞在状態を推定する手法を提案している。提案手法における移動滞在部では、liu 等 [23] の手法を実装した。

3.3 推定候補ペア抽出

提案手法において、2 者間の関係性有無を推定するために各種特徴量を算出する必要がある。ユーザ数 M に対して、総ペア数は、 $M(M-1)/2$ となる。長期間の位置情報履歴を持つユーザ間に対する総ペアへのリンク特徴量計算は、非現実的である。そこで我々は、前処理にて滞在状態と判定された位置情報が、処理期間中に任意の時空間メッシュを一定数以上共有するユーザペアを推定候補ペア $CandU = (cu_1, cu_2, \dots, cu_O)$ として抽出する。本研究における時空間メッシュは、 $900m \times 900m \times 3hours$ の 3 次元空間とし、共有回数は、1 回以上とした。本処理は、後述処理を軽減するためのフィルターであるため、時空間メッシュは、両者の同時滞在を検知するにあたり十分な大きさを確保している。

3.4 リンク推定特徴量

推定候補ペア抽出にて算出した $CandU$ に対して、リンク推定に用いる特徴量を算出する。本提案では、候補者における行動分析を行ない、候補ペア間の同時行動、行動共有シーン、行動共有パターンの 3 軸によるリンク推定に関わる特徴量による 120 通りの組み合わせによってリンク有無を推定する。3 軸の特徴量について詳細を説明する。

3.4.1 同時行動

$CandU$ 間による同時空間共有行動を検出し特徴量とす

る。同時行動は、6種の同時滞在行動と2種の同時移動行動に分類され、それぞれの発生回数を算出する。まず、同時滞在行動において、候補ペア間において、同時刻に滞在地が任意の距離以内である状態を同時滞在とする。本実験においては、滞在地間の距離を300m以内であれば、同時滞在として検知した。また、我々は、Wang等[17]と同様にそれぞれの場所に対してユーザ個人が持つ意味合い（自宅や職場など）も考慮した特徴量算出を行った。以下に、同時行動にて用いる時空間共有の特徴を示す。

(1) 同時滞在行動

全滞在地

移動滞在判定部で出力される滞在地における候補ペア間の共有を検知

全主要滞在地

全滞在地中において α 日中、 β 日以上 γ 時間以上滞在していた場所を主要滞在地として抽出した上で、候補ペア間における主要滞在地の共有を検知

自宅

主要滞在地において、午前0時～3時における滞在回数の最も多かった主要滞在地を「自宅」として判定し、候補ペア間の自宅の共有を検知

職場

主要滞在地において、午前10時～午後4時における滞在回数の最も多かった主要滞在地を「職場」として判定し、候補ペア間の職場の共有を検知

自宅・職場以外の主要滞在地

自宅及び職場に判定されなかった主要滞在地における候補ペアの時空間共有を検知

主要滞在地以外の滞在地

主要滞在地に判定されなかった滞在地（非日常的な滞在）における候補ペアの時空間共有を検知

(2) 同時移動行動

移動軌跡

移動滞在判定部で出力される移動判定された位置情報履歴から、候補ペアの位置情報間における時空間距離の平均から一致度を判定し、同時刻に同じ移動軌跡を辿っている状態を同時移動状態として検知

移動手段

移動滞在判定部で出力される移動判定された位置情報履歴から道路中心線情報に対してマップマッチング処理を行ない移動手段（例 山手線、国道1号線等）を推定した上で、候補ペア間における同時刻に同じ移動手段を利用している状態を同時手段利用状態と検知

3.4.2 行動共有シーン

我々は、前節で述べたCandU間の同時行動が発生した状況を行動共有シーンとして、全日、平日、休日、平日退

表 1 被験者グループ構成員とグループの関係性

構成員数	グループ数
11人グループ	1
10人グループ	1
5人グループ	1
4人グループ	2
3人グループ	5
2人グループ	22
1人グループ	5

社後の4種で細分化して、特徴として利用した。平日退社後における退社時間は、前節の職場判定結果を利用した上で、退社時間を算出している。

3.4.3 行動共有パターン

我々は、関係性を推定する上で、同時行動が発生するパターンについても頻度だけでなく複数の指標が存在すると考えている。定期的に行動を共にするだけでなく、1日もしくは、1回に長時間の同時行動を行う候補ペアにおいても関係性有無を判定する重要な指標であると考え。そこで、同時行動が発生するパターンとして、接触積算時間、接触日数、平均継続接触時間、最大継続接触時間の4種類を特徴として利用した。本論文における接触とは、任意の時間における2者の位置が300m×300m×1hours時間の時空間メッシュに存在することを意味する。

4. 正解データ及び位置情報履歴収集実験

本提案手法の評価を行うにあたり、我々は、実験開始から終了まで関係性に变化のない複数グループを対して、位置情報履歴収集及び、関係性についてのアンケート調査を実施した。本実験における被験者数は、98名であり、データ取得期間は、2016年1月30日から2016年3月15日までの約1ヶ月半である。被験者は、本実験用に独自開発したスマートフォンアプリケーションにより定期的に位置情報を発信し、実験期間における位置情報に関しては、実験用サーバに記録した。アンケート調査によって関係性の正解ラベルが付与されたリンクが159ペアであり、本論文の目的としては、98名による4753ペアから159ペアを推定する問題を解くことである。関係性のある被験者グループは、32グループであった。表1に被験者グループ構成員数とグループ数を示す。関係性の種類は、夫婦、恋人、家族、サークル仲間、同僚などさまざまであった。実験にて得られたデータについて、被験者から、本研究の目的において被験者間の関係性についての詳細分析や外部発表について明確な個別許諾をいただいた上で研究を行なっています。

5. 評価

本章では、データ収集実験によって収集したデータに基づいた提案手法の評価について述べる。アンケート調査により取得した関係性の正解ラベル付きのユーザを入力として

表 2 精度評価における混合行列

	推定：正	推定：負	合計
正解：正	94	65	159
正解：負	587	4007	4594
合計	681	4072	4753

本提案手法により位置情報履歴から人間関係のリンク推定を行ない、正解データと推定結果の比較を行うことで、推定精度の評価検証を行なった。評価実施にあたり、時空間メッシュ共有状態に基づく推定候補ペア抽出を実施した。抽出された候補ペアに対して、関係性有無を推定し、その精度を評価した。各評価について以下に詳細を述べる。

5.1 推定候補ペア抽出処理

被験者 98 名からなる 4753 組について $900m \times 900m \times 3\text{hours}$ の時空間滞在メッシュを 1 つ以上共有するペアを候補ペアとして抽出した。抽出結果として、681 候補ペアが抽出された。また、正解ラベル付きの 159 ペアの内、94 ペアを候補ペアとして正しく抽出できたが、65 ペアは抽出されなかった。表 2 に候補ペア抽出における混合行列を示す。

5.2 リンク推定のための分類器生成とその評価

前節の推定候補ペア抽出にて候補ペアとして抽出された 681 ペアについて、提案した特徴量を算出し、リンク有無の推定を行った。生成した特徴量は、それぞれ機械学習アルゴリズムに基づく学習と集計値に基づいたルールベースモデルの 2 種の分類器でそれぞれ精度評価を実施した。

5.2.1 機械学習による分類器とその評価

機械学習による分類器において本論では、Random Forest を利用してモデルを構築した。利用した特徴量は、前章で述べた 120 種類をすべて利用して分類器を作成した。評価においては、交差検証 ($n = 3$) を行っている。結果として Accuracy が 0.922, Precision が、0.847, Recall が、0.532 であった。本分類器では、リンクがある 94 ペアの中で 50 ペアを正例として判定し、リンクがない 587 ペアの中で 578 ペアを負例として分類したこととなる。これらの結果を候補ペア抽出から遡って評価すると 99.8% の精度で他人と他人として判定可能である一方で、31.4% の知人を発見可能な分類器となっている。

図 2 に Random Forest にて利用した特徴量の重要度 Top20 を示す。上位 4 特徴量は全日の全ての滞在地の同時滞在に対するスコアが高い状態にある。一方で 5 位に、本提案手法の特徴の 1 つである全日の移動軌跡の同時移動が入っていることがわかる。休日や平日退社後の特徴量は Top20 以下の下位となった。Eagle 等 [10] 等の事例では、業務時間外、つまり非日常における時空間共有が関係性を評価する重要な指標であると結論付けられているが、本論




図 2 RandomForest による特徴量の重要度 Top20

における被験者は、家族や同僚など日常行動を共にするグループ群も多数あったため、特徴が現れたと思われる。

5.2.2 集計値に基づくルールベース分類器とその評価

我々は、正例と負例の間で変化量大きい特徴量を個々に確認し、その閾値を手で設定して作成したルールベース分類器での評価も合わせて実施した。正例と負例及び全データにおける特徴量の差を経験累積分布関数 (CDF) で個々に確認し、性能差への影響度を目視で確認しながらパラメータを設定した。図 4 に全日の全滞在地における CDF グラフを示す。全日における全滞在地における共有積算時間、接触日数、継続接触平均時間、継続接触最大時間において、正例と負例に有意な差が見られた。Precision と Recall が良好となった閾値は、それぞれ積算時間は 7200 秒以上、接触日数は、2 日以上、継続接触平均時間は、5400 秒以上、継続接触最大時間は、6600 秒以上であった。

さらに、非日常における同時行動においても明示的に正例と負例を分類できる特徴量が見つかった。図 5 に非日常時の同時行動における CDF グラフを示す。各グラフにおいて、負例がほぼ存在なくなり、正例だけが残る閾値が存在する。少数ではあるが、非日常におけるパラメータによって、確実に正例を区別することが可能であることがわかった。全日におけるその他滞在地と休日における全滞在地の接触日数については、3 日以上で分離可能であり、平日退社後における滞在、休日における同時移動については、値の有無で分離が可能であった。これらの結果に基いて、我々は、表 3 のようにルールベースモデルの閾値を定めた。精度評価を行うに当たって、全日全滞在地の閾値をすべて満たすことを条件とした評価条件 A とその他特徴量の閾値を 1 つでも満たすことを条件とした評価条件 B、評価条件 A 若しくは評価条件 B を満たすことを条件とした評価条件 C の 3 つに対して評価した。評価条件 A, B 及び C における性能評価値を表 4 に示す。表 4 の結果より、評価条件 C において、ほぼ Random Forest による結果と同等に精度であることがわかった。Recall が 0.574 となり、関係性の

表 3 ルールベースモデルの閾値

同時行動と共有シーン	共有パターン	閾値
全日全滞在地	接触積算時間	7200 秒以上
	接触日数	2 日以上
	平均継続接触時間	5400 秒以上
	最大継続接触時間	6600 秒以上
平日退社後+全ての滞在	接触積算時間	2000 秒以上
平日退社後+全ての滞在	接触日数	2 日以上
全日+その他の滞在地	接触日数	3 日以上
休日+全ての滞在	接触日数	3 日以上
平日+その他の滞在	接触日数	3 日以上
休日+移動手段	平均継続接触時間	600 秒以上
全日+自宅滞在	接触日数	3 日以上
全日+主要滞在	接触日数	16 日以上
平日+職場滞在	接触日数	10 日以上
全日+職場滞在	平均継続接触時間	22000 秒以上
全日+移動手段	平均継続接触時間	3200 秒以上

表 4 評価条件 A, B 及び C における性能評価値

	Accuracy	Precision	Recall
評価条件 A	0.889	0.698	0.468
評価条件 B	0.918	0.975	0.415
評価条件 C	0.913	0.740	0.574

ある人々を抽出可能な確率が多少増え、誤認も抑えることができたと言える。また、非日常系特徴量や自宅・職場特徴量に関する評価条件 B については、関係性のない人々を関係ありと誤認することはほとんどなく、ロバストに「関係あり」といえる関係を抽出することが得意な特徴量だと言える。本評価のベースラインにおける Accuracy は、0.862 であり、提案手法によって分類精度が向上したことがわかる。

図 3 にルールベース分類器によって正しく関係性ありと判定されたペアの行動軌跡例を示す。本提案にて考慮された 2 者での長距離に及ぶ同時移動が検出されており、これらの共有行動が判定に良い影響を与えた一例となる。

6. 議論

本論では、時空間移動における行動分析から任意の 2 者間に対する社会的な人間関係の有無を推定することを目的としている。また、本分野の既存研究は、位置情報を用いたソーシャルネットワークサービスの利用ログ分析によって関係性を推定しており、サービス加入者間の関係性分析に留まっている。社会的な人間関係には、夫婦や家族、恋人、友人、同僚などさまざまな形態がある。しかしながら、本論も合わせた本分野の研究では、異種関係性を一意に扱うことを前提にモデルを生成している。位置情報を用いたソーシャルサービス利用者間の関係は、サービスの性質上、友人関係者が多いと思われる。一方で、本論における被験者は、さまざまな形態が存在し、形態ごとに同時行動の特徴も異なる可能性が高い。一般論ではあるが、家族や同僚は日常的な同時行動が頻繁に発生し、恋人や友人は、非日

常的な同時行動が多いと思われる。残念ながら我々の実験においては、学習に十分な異種関係性ごとの正解データを準備できなかったため、本仮説の検証を十分に行えなかったが、今後の発展に向けて関係性の種類も意識した推定モデル検討を進めていく必要があると思われる。

7. まとめ

本論では、仮想世界や限定空間での人間関係分析ではなく、広範囲に及ぶ物理空間での位置情報を用いた実空間における人間関係分析技術に注目し、2 者間の同時行動に対して、共有の行動、シーン、パターンの 3 軸による特徴量を用いたモデルを提案した。提案モデルでは、既存研究では考慮されていなかった同時移動行動と同時滞在行動の両面から共有行動のモデル化を行った。提案手法の評価にあたり、約 1 ヶ月半による 98 名の継続的な GPS データと関係性に関するアンケート調査を実施し、正解データを収集し、Random Forest による分類器と集計値に基づくルールベース分類器による精度評価を実施した。評価結果において、機械学習による分類器とルールベース分類器に大きな精度の違いはないが、ルールベースにおいて Precision を上げるパラメータ設定を見出した。平均的に Accuracy は 0.9 前後となった。

今後の課題として、同被験者の滞在チェックインデータや全軌跡データを用いた既存手法と本手法との精度評価を実施するとともに、全章で述べた異種関係性における正解データの再取得及び、関係性単位でのモデル生成と評価を実施し、実空間における人間関係分析の精度向上に貢献する。

参考文献

- [1] 松尾 豊, 友部博教, 橋田浩一, 中島秀之, 石塚 満: Web からの人間関係ネットワークの抽出, 人工知能学会論文誌, Vol.20, No.1, pp.4656 (2005)
- [2] Gilbert E, Karahalios K. Predicting tie strength with social media. In: Proceedings of the SIGCHI Conference on Human Factors in Computing Systems. 2009 Presented at: SIGCHI Conference on Human Factors in Computing Systems; April 4-9, 2009; Boston, MA p. 211-220.
- [3] B. N. Waber, D. Olguin, T. Kim, A. Mohan, K. Ara, and A. S. Pentland, "Organizational Engineering using Sociometric Badges," Proc. NetSciInternational Conf. Netw. Sci., pp. 20 25, 2007.
- [4] D. Olguin and J. Paradiso, "Wearable communicator badge: Designing a new platform for revealing organizational dynamics," Symp. Wearable, 2006.
- [5] Y. Wakisaka, K. Ara, M. Hayakawa, Y. Horry, N. Moriwaki, N. Ohkubo, N. Sato, S. Tsuji, and K. Yano, "Beam-scan sensor node: Reliable sensing of human interactions in organization," INSS2009 - 6th Int. Conf. Networked Sens. Syst., pp. 5861, 2009.
- [6] S. Tsuji, N. Sato, R. Otsuka, F. Beniyama, and K. Yano, "Business Microscope Display: Activity Log Application for Attracting Workers and Encouraging Communication in the Office," FIT2012, vol. 69, pp. 6976, 2012.




図 3 正しく関係性有りと推定されたペアの行動軌跡例




図 4 全日の全滞在地における CDF

- [7] N. M. Satomi TSUJI, Nobuo SATO, “Visualization Communication — Style by Business Microscope,” Inst. Electron. Inf. Commun. Eng., vol. 45, 2007.
- [8] 石塚宏紀, 小野智弘, 山本直人, 伊藤昌毅, 瀬崎薫, “Bluetooth による近接性を用いた実空間人間関係抽出手法の実装と評価 “, マルチメディア, 分散, 協調とモバイル (DICOMO2015) シンポジウム, pp. 1721-1728, 2015 年 7 月.
- [9] H. Pham, C. Shahabi, and Y. Liu, “EBM- An Entropy-based Model to Infer Social Strength from Spatiotemporal Data,” in Proc. 2013 International Conference on Management of Data. ACM, 2013, pp. 265276.
- [10] N. Eagle, A. S. Pentland, and D. Lazer, “Inferring Friendship Network Structure by Using Mobile Phone Data,” Proceedings of the National Academy of Sciences, vol. 106, no. 36, pp. 15 27415 278, 2009.
- [11] D. J. Crandall, L. Backstrom, D. Cosley, S. Suri, D. Huttenlocher, and J. Kleinberg, “Inferring Social Ties from Geographic Coincidences,” Proceedings of the National Academy of Sciences, vol. 107, no. 52, pp. 22 43622 441, 2010.
- [12] J. Cranshaw, E. Toch, J. Hong, A. Kittur, and N. Sadeh, “Bridging the Gap Between Physical Location and On-line Social Networks,” in Proc. 12th ACM International Conference on Ubiquitous computing. ACM, 2010, pp. 119128.
- [13] J. Chang and E. Sun, “Location3: How Users Share and Respond to Location-based Data on Social Networking Sites,” in Proc. 5th International Conference on Weblogs and Social Media. The AAAI Press, 2011.
- [14] Q. Li, Y. Zheng, X. Xie, Y. Chen, W. Liu, and W.-Y. Ma, “Mining User Similarity Based on Location History,” in Proc. 16th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. ACM, 2008, p. 34.
- [15] Y. Zheng, L. Zhang, X. Xie and W.-Y. Ma “Mining interesting locations and travel sequences from gps trajectories “ Proc. WWW,
- [16] X. Xiao, Y. Zheng, Q. Luo and X. Xie “Finding similar users using category-based location history “ Proc. GIS, pp. 442-445,
- [17] H. Wang, Z. Li, and W.-C. Lee, “PGT: Measuring mobility relationship using personal, global and temporal factors,” in Proc. 14th IEEE International Conference on Data Mining (ICDM). IEEE, 2014, pp. 570579.
- [18] Y.ZhangandJ.Pang, “Distanceandfriendship:A distance-basedmodel for link prediction in social networks,” in Proc. 17th Asia-Pacific Web Conference, ser. LNCS. Springer, 2015,
- [19] 関本義秀, 人の流動と時空間データセット最前線, オペレーションズ・リサーチ誌, Vol.58, No.1, pp.24-29, 2013.1.
- [20] D. Ashbrook, and T. Starner, “Using GPS to learn significant locations and predict movement across multiple users,” Journal of Personal and Ubiquitous Computing, vol.7, no.5, pp.275-286, 2003.
- [21] P. Nurmi, and S. Bhattacharya, “Identifying meaningful places: The non-parametric way,” Proc. of the 6th International Conference on Pervasive Computing, pp.111-127, 2008.
- [22] J. H. Kang, W. Welbourne, B. Stewart, G. Borriello, “Extracting places from traces of locations “, ACM SIGMOBILE Mobile Computing and Communications Re-




図 5 非日常の同時行動における CDF

view, v.9 n.3, July 2005

- [23] J. Liu, O. Wolfson, H. Yin, “Extracting Semantic Location from Outdoor Positioning Systems,” Proc. of the 7th International Conference on Mobile Data Management (MDM 2006), pp.73, 2006.