

Bluetooth デバイスの検出履歴を用いた ユーザ行動の分類

牛越達也[†] 出射健一郎[†] 西出亮[†] 河野恭之[†]

本稿では、環境中に存在するあらゆる Bluetooth 機器を対象に、ユーザが常時携帯する Bluetooth 機器から得られる検出履歴を分析しユーザの行動を推定できる可能性について述べる。ユーザが得られる検出履歴の特徴は場所や状況によって異なり、行動分類に有効な分節パラメータの選択が重要になる。

1. はじめに

1.1 背景と目的

本研究では、携帯電話、PDA、ノート PC や家電製品など様々な電子機器に急速に普及し我々の環境に遍在しつつある Bluetooth 機能を搭載した製品を検出し、検出履歴を解析することでユーザの行動を分類することを目的とする。Bluetooth 機器は通信相手からの Inquiry(問い合わせ)に应答するため、通信範囲内にある Bluetooth 機器からの検出が可能な状態にある。この特性を利用し本研究では、ユーザが携帯する Bluetooth 機能付き PC/PDA により周囲の Bluetooth 機器を常時検出して記録しておき、その履歴を解析することでユーザ行動の自動分類・タグ付けを目指す。更に本研究ではユーザの日常的な行動をイベントと定義し、検出履歴からイベント候補を生成することを目的とする。イベントとは、例えばユーザが誰かと共に歩いていた、ユーザがある場所で長時間滞在した等のユーザ行動の主観的な区分を指す。

ユーザが得られる Bluetooth 機器の検出履歴は、図 1 のように周囲の場所や状況に応じて異なる。例えば講義室で講義を受けている間は室内の人物の入れ替わりが少なく、Bluetooth 機能を有する携帯電話の Bluetooth Device Address¹ (以下 BDA)が連続して検出される。また、電車内やバス内では、走行中は複数の BDA が安定して検出されるが停車すると複数の BDA が入れ替わり検出される。自宅に居る間は、PC や Wii など場所に設置されている BDA が長時間検出され、食堂に立ち寄れば短時間で複数の人物の所持する携帯電話の BDA がすれちがいに検出される。これらの例のように、ユーザが居る場所や状況によって検出履歴の特徴をとらえることで、ユーザの行動を

イベントごとに区切ることが可能であると考えられる。そこでユーザが Bluetooth 機器を携帯・装着して行動し、その間周囲の Bluetooth 機器の BDA を連続的に取得し、得られた BDA と時刻情報を同時に記録する。そして記録したデータを用いてイベント候補を生成し、イベント候補ごとの特徴や傾向を分析することでイベントの分類を行う。

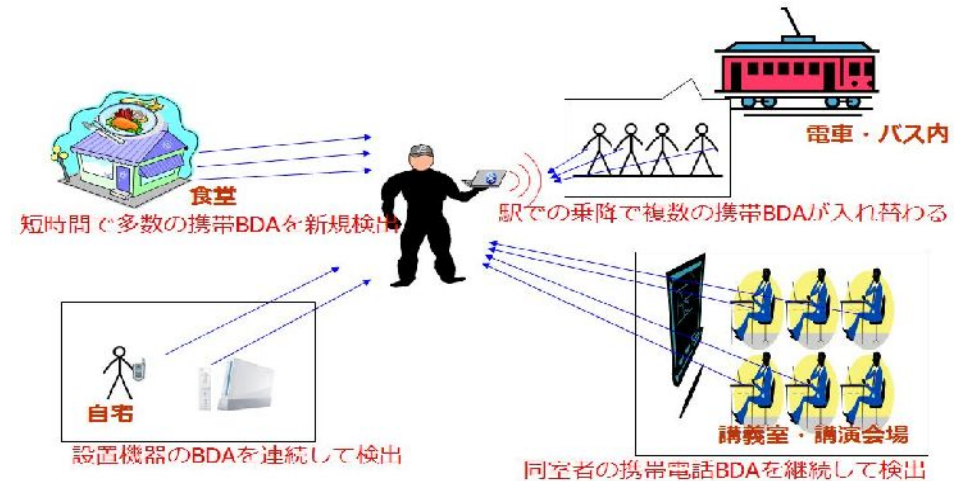


図 1 : 様々な場所・状況での周囲の Bluetooth 機器検出状況

1.2 関連研究

人の日常行動を、携帯するデバイスや環境中に存在するセンサなどを用いて場所情報や時間情報などを履歴データに保存・分析し、想起に役立つライフログ関連の研究が現在まで多くなされている。Ashbrook らは、GPS から得られるユーザが位置する経度・緯度情報を一定時間毎に記録し、ユーザが一定時間滞在する範囲の領域を有意位置と定義し、記録したデータに対し k-means 法[1]の変種を適用することで有意位置を抽出し、HMM(Hidden Markov Model)[2]を用いてユーザが次に行く場所の予測を行っている[3]。また瀬古らは同行人判定のため、同じ型番の機種種の GPS を所持した二人が、同じルートを通った際における GPS 計測結果の誤差情報を利用している[4]。Petteri らは、非連続な GPS データからノンパラメトリックベイズ法を用いることでユーザがよくいた場所を識別しており、さらに時間情報を用いずに特定することができる[5]。これらの研究は、一般ユーザへの普及が少ないと考えられる GPS を用いて行動パターンの推測や同行人判定や場所の特定を行っている。Xuchai らは、家の中に設置された

[†] 関西学院大学大学院理工学研究科
Graduate School of Science and Technology, Kwansai Gakuin University

¹ Bluetooth 機器の製造段階に各機器を識別するために割り当てられた固有 ID(MAC アドレス)

複数のマイクロホンがユーザの行動から発せられるあらゆる音を拾い、分析することでユーザの位置特定を行っている[6]。また Aipperspach らは、UWB(Ultra Wideband Sensor)を用いてユーザの位置特定を行い GMM(Gaussian Mixture Model)を用いてユーザが家の中でよく居る場所を発見する[7]。これらの研究においては、家の中でのユーザの場所や位置を発見するために事前に家の中に複数のセンサを設置する必要がある。山根らは、ユーザが日常行動を携帯端末上のアプリケーションに対して行動の種類・内容・場所・評価等の文脈情報を随時入力し、蓄積されたデータに統計処理をかけることで行動履歴が持つ特徴を取り出し、その中から行動の内容や時間の使い方が上手な模範行動を選択することで現在の状況を考慮した予定の作成を行うシステム AcTrec[8]を開発したが、ユーザが行動を起こす度に文脈情報を手動で入力しなければならない煩雑さがある。Timothy らは携帯電話の GSM 電波強度のみを用いてユーザの行動(歩行中、運転中、停滞中など)を識別しているが、周囲の人や物の状況は行動の識別に考慮されていない[9]。本研究では、ユーザが Bluetooth 機器を持ち歩くだけで周囲の BDA を自動的に検出するのでユーザに負担がかからず、また場所に依存せず検出が可能である。

2. 研究概要

2.1 Bluetooth Device Address の検出

すべての Bluetooth 機器にはそれぞれ固有の ID として、48 ビットの MAC アドレスが製造時に割り当てられる。これらは Bluetooth Device Address(BDA)と呼ばれており、Bluetooth 機器同士で通信を行う際に BDA を交換してお互いに機器を識別する。このため Bluetooth 機器同士がお互いを認証し通信可能な状態になっていなくても BDA 交換は行われる。この特性を利用して①ユーザが携帯/装着する Bluetooth 機器から定期的に探索(Inquiry)信号を発信することで、各時刻においてユーザの周囲にある Bluetooth 機器の集合を獲得・記録し、②その履歴を解析して周囲状況を推測するというのが本研究のアイデアである。

Bluetooth 機器は、Wii や PC などの場所に固定されている属地性のある機器と、携帯電話や PDA などの人が装着したり携帯したりしてユーザと共に移動する属人性のある機器の 2 種類に分けられる。属地性のある Bluetooth 機器がユーザの周辺に存在すると、ユーザが付近に停滞している間はその BDA が連続して検出されるのに対し、属人性のある機器の BDA の検出履歴は、機器を所持する人物の行動によって左右される。本研究では BDA を取得するにあたって、一般普及している class2(到達距離 10m)の Bluetooth 機器を用いるものとする。携帯電話や PC など、Bluetooth 機器の種類を確認するため予備調査を行った結果、検出されるほとんどの Bluetooth 機器が携帯電話で

あることが判明した。検出される携帯電話の多くは Softbank 製であり、これは Softbank 製 Bluetooth 機能付き携帯電話の一部機種で購入時設定が Discovery mode²であることが原因であると推測される。

本研究では[11]を参考に Inquiry 時間を 6 秒、Inquiry 周期を 20 秒とし BDA のデータ収録を行った。Bluetooth の Inquiry は、始めに周囲の Bluetooth 機器の BDA を取得し、次に各 Bluetooth 機器にデバイス名の問い合わせをするプロトコルになっている。本研究では Inquiry で得られる周囲の BDA とその際の時刻情報を組にして、20 秒毎にテキストファイルに記録する。また、本研究で携帯する Bluetooth 機器は class2 のノート PC であり、ユーザから約 10m 圏内にある BDA が検出可能である。class2 の約 10m は、室内程度であれば全体を包含するので、室内に存在する Bluetooth 機器の全ての BDA が検出できる。図 2 は属人、属地両方の Bluetooth 機器が複数混在し、かつ室内という条件を満たす大学研究室にて、実際にノート PC を用いて問い合わせを行った様子を示す。研究室にある Bluetooth 機器には、PC、携帯電話、Wii などがあり、これらの機器は電源が入っている間は BDA が検出可能状態にある。例えば研究室に人が複数居る場合は、ある人物が PC を操作していればその間は PC の BDA が取得でき、Bluetooth 機能を搭載している携帯電話をある人物が所持している場合、その人物が研究室に居るだけで携帯電話の BDA が検出される。このように、ユーザが日常行動の中で Bluetooth 機器を持ち歩くだけで周辺の BDA と検出時刻が取得できる。

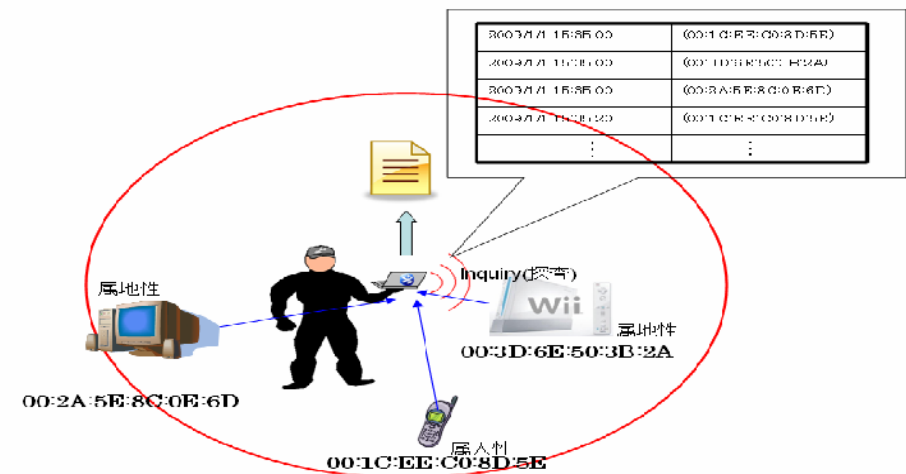


図 2 研究室における BDA の取得状況

² Discovery mode…周辺 Bluetooth 機器から発見可能になっている状態

2.2 システム構成

本研究が想定するシステムの構成を図3に示す。まず得られたBDA検出履歴から、イベント候補を分類する検出ルールを参照してイベントの端点候補を抽出しユーザに提示する。提示された候補が不適切であれば、ユーザはその端点候補を削除するもしくはユーザにとって正しい位置に移動させる。ユーザによる修正をトリガとして学習器が検出ルールを更新する。このシステムが実現すると、様々なイベントのパターンの学習を行うことでユーザが過去に行動したイベントの自動分類が可能になる。このようなシステム実現のために、本稿ではまず1. BDA検出履歴の中でイベントの端点を特徴づける分節パラメータを見つけ出し、2. これらの分節パラメータを用いてイベント端点候補を検出する検出ルールを構築した。




図3 システム構成

2.3 検出履歴の特徴

2.3.1 イベントタイプの定義

検出履歴の特徴からユーザ周囲の状況を分類し、イベントをタイプごとに分類する。イベントとは2つのイベント端点の間の区間であり、そのタイプは以下3つの条件から構成されるものとする。

- ①人数
- ②期間
- ③ユーザと周囲の状況

①人数の定義

大人数 ⇒ ユーザ周辺に人が多数集まる状況

少人数 ⇒ ユーザ周辺に人が居ない、または少数居る状況

②期間の定義

長期間 ⇒ イベントが30分以上の長さ

短期間 ⇒ イベントが30分未満かその程度の長さ

③ユーザと周囲の状況の定義

滞在 ⇒ ユーザ、またはユーザ周辺の人物の滞在している時間が長い状況

移動 ⇒ ユーザ、またはユーザ周辺の人物の移動している時間が長い状況

入れ替わり ⇒ イベント期間の途中で周囲の人数が増減する回数が多い状況

2.3.2 実験データの特徴

図4は2009/3/13に被験者が横浜市内で開催された学会を神戸から聴講しに行った際の昼間の検出履歴である。なお被験者はclass2のBluetoothアダプタをノートPCに接続し、ノートPCを常時携帯し収録すると共にイベント endpoints, すなわち被験者が行動や周囲状況が変化したと感じる時点の時刻とその状況変化をメモとして記録した。このグラフは横軸に検出時刻、縦軸にBDAが出現した順に1から番号を割り当てたもの(デバイスID)の散布図になる。この日のユーザの主な行動履歴を検出履歴と照らし合わせたイベントタイプを表1に記す。




図4 2009/3/13 東京出張の検出履歴

表1 ユーザの状況とそれぞれのイベントタイプ

イベントID	ユーザの状況	イベントタイプ
A, E, G	都市近郊電車内	大人数短期間入れ替わり型
C, L	新幹線内, 学会セッション中	大人数長期間入れ替わり型
B, D, F	駅構内移動	大人数短期間移動型
J	学会セッション中	大人数短期間滞在型
K	委員会会議室	少人数長期間入れ替わり型
H, M	徒歩(駅や会場からバス停)	少人数短期間移動型
I, N	バス内	少人数短期間入れ替わり型

各イベントタイプについての特徴を述べる。

A, E, Gはユーザが都市近郊電車内に居る区間である。このイベントでは周囲に人が比較的多いため短期間で複数のBDAが連続して検出され、かつ電車が駅に停車する毎に人の入れ替わりが発生するという大人数短期間入れ替わり型となる。

C, Lはそれぞれ新幹線内と学会セッション中の区間である。これらのイベントでは周囲の人が長期間その空間に滞在するため複数のBDAが連続して検出され、新幹線の停車やセッションの区切りにより人の入れ替わりが発生するという大人数長期間入れ替わり型となる。なおC及びLには断続的に観測されるBDAが含まれるが、これらの多くはノートPCであり、電源のON/OFFに対応して検出状況が振動したと考えられる。

B, D, Fはユーザが駅構内を徒歩で移動している区間である。このイベントでは周囲の人とのすれ違いが激しいため新規に検出されるBDAが多い。また、ユーザも周囲の人も移動している時間が短いため大人数短期間移動型となる。

Jは学会セッション中の区間でLと同じイベントであるが、比較的滞在時間が短くイベント期間の途中で人の入れ替わりがほとんど無かった大人数短期間滞在型となる。

Kはユーザが委員会会議室に居る区間である。このイベントは周囲に人が少ないが、途中入室や会議参加者の出入りがあったため少人数長期間入れ替わり型となる。

H, Mはユーザが駅や学会会場からバス停まで歩いているイベントである。このイベントは周囲にあまり人がいなくBDAがほとんど検出されなかった少人数短期間移動型となる。

I, Nはユーザがバス内に居るイベントである。このイベントは周囲の人の数は少ないが、バスが停車する度に少数の人の乗り降りがあり新規のBDAが検出された少人数短期間入れ替わり型となる。

3. イベント分節パラメータと検出ルール

検出履歴からイベント端点候補を抽出するためには、検出履歴中でイベント端点を特徴付けるパラメータが必要である。ここではまず複数の収録データを人手で分析して端点の検出に寄与する分節パラメータの候補を挙げる。そしてデータマイニングツールとしても利用されている決定木学習システム C4.5[10]で履歴の各サンプル点の分節パラメータと正解ラベルとの組を事例集合として与えてそれらを分類する決定木を生成させ、分類に寄与するパラメータを抽出することで分節パラメータを選択した。これらの選択された分節パラメータを組み合わせて訓練データから端点検出ルールを作成した。

3.1 BDA の補間

周囲に存在するにもかかわらずタイムアウトまでに Inquiry 信号に対する応答がされない場合があり履歴中のノイズ要因となる。この問題を解決するために検出履歴から各 BDA の総検出回数に応じた欠落区間を埋める形で補間を行った。

3.2 検出履歴からの分節パラメータ考案

表 1 のように日常生活での行動は多種多様である。イベントを上手く特徴付ける分節パラメータを考案する必要がある。以下に、2009/3/13 の検出履歴から考案された分節パラメータとその特性を述べる。

①同時検出数

同時刻検出された BDA の数であり、周囲の Bluetooth 機器の密集度(人の密集度)を表す。この値が大きいことは、ユーザが多数数の集まっている場所にいる、あるいは人の集団と一緒に移動している可能性を示す。

②総検出回数

ある時間範囲中の各 BDA の総検出回数であり、そのデバイスとユーザが共在していた時間長に対応する。この値が大きいことは、ユーザが長時間同じ人物と一緒に居る、または同じ場所に居続けている可能性を示す。

③新規 ID 検出数

履歴中になく新しい BDA の単位時間当りの検出数であり、ユーザまたは周囲の人物の状況が滞在から移動、または移動から滞中に遷移した場合に値が変化する。この数値が大きいとユーザが人の集団の中に侵入した可能性を示し、小さいとユーザと周囲の人物の状態に変化が少ないことを示唆する。

④新規同時検出数

一定期間継続して検出される BDA が新規に検出された時の検出数である。検出履歴の中で既に検出されている BDA を含まない点で①とは異なる。また、すれ違う人物が持つ携帯デバイスの数を含まず、複数の人物と共在を開始する可能性にしぼる点で③とは異なる。新規 BDA が同時刻に複数検出されることは、あるイベントが開始または終了した可能性を示す。

⑤同時消失数

複数の BDA が同時刻あるいは一定時間内に検出されなくなった場合の数。場や状況からユーザが離脱した可能性を示す。

なお④新規同時検出数と⑤同時消失数に関しては検出履歴中の各 BDA を長時間連続で検出されている Long_term か、短期間検出されている Short_term のどちらかに分類し、それぞれ分類されたデータに対して新規同時検出数と同時消失数を算出する。

⑥同時検出数の変化量

①同時検出数の単位時間当りの変化量、すなわち共存する Bluetooth 機器の時間微分値である。この数値が大きいと、ユーザが Bluetooth 機器が密集する場の中で移動している可能性を示す。

⑦総検出回数の合計値の変化量

ある時点に含まれている BDA の総検出回数の合計値の変化量であり、長期のイベントなどが開始した時点でこのパラメータは大きな値を示す。この数値が大きいと、ユーザが同じ場所での長時間の滞在を開始した可能性を示す。

⑧新規 ID 検出数の変化量

③新規 ID 検出数を微分した値である。この数値の絶対値が大きいことは、ユーザが Bluetooth 機器の密集度が異なる場に侵入した可能性を示す。

⑨同時検出数の変化量の微分

⑥同時検出数の変化量の時間微分値である。この値の絶対値が大きいことは、ユーザが Bluetooth 機器の密集度が異なる場に侵入した可能性を示す。

⑩新規単独検出数

Short_term と分類された BDA の中で単一のデータでかつ同時刻に検出された数。この値が大きいと、ユーザが多数の人物とすれ違うか多数の人間を乗せた車両がユーザのそばを通過した、あるいはユーザが乗った車両が人を密集する場を通過した可能性を示す。

3.3 C4.5 による分節パラメータの選択

3.2 節で考案された分節パラメータのうちイベント候補の検出に有効である分節パラメータの選択が必要になる。本研究では C4.5 を用いて、ユーザが検出履歴に正解ラベルを与え、考案された複数の分節パラメータを用いて C4.5 で評価を行う。訓練データとして図 4 に示した 2009/3/13 の検出履歴で評価を行った。その結果、イベント端点候補の検出に、新規 ID 検出数・新規同時検出数・同時消失数・同時検出数の変化量・総検出回数の変化量・新規 ID 検出数の変化量・同時検出数の変化量の微分が寄与することがわかった。

3.4 検出ルールの作成

ここではイベント候補の端点候補を抽出する検出ルールの作成を行う。検出履歴ごとの検出ルールを作成することで、似た特徴を持つ検出履歴のイベント候補の端点検出が可能になる。そこで本研究では、2009/3/13 の検出履歴に対してイベントの端点を正例(T)として与えイベント端点とし、それ以外の点を負例 F とおき、3.3 節で有効であると判断された分節パラメータを用いて、これらのパラメータが正か負かの総当りで組み合わせて決定木を生成し、評価の高いルール群を抽出した。ルールの評価には、他の枝でカバーされない正例を多くカバーし(高検出率)、かつ負例を検出してしまわず(すなわち過検出が少ないもの)を高評価とした。高検出率と低過検出率はトレードオフの関係にあるため、提示される候補の修正を行うことになるユーザの負荷を考慮して正例の 3 倍程度までの過検出を許容することとした。

今回用いた分節パラメータを、

新規 ID 検出数 ⇒ Inc
 Long_term の新規同時検出数 ⇒ Long_S

Short_term の新規同時検出数 ⇒ Short_S
 Short_term の同時消失数 ⇒ Short_E
 同時検出数の変化量 ⇒ Same_V
 総検出回数の変化量 ⇒ Total_V
 新規 ID 検出数の変化量 ⇒ Inc_V
 同時検出数の変化量の微分 ⇒ Same_V2
 新規単独検出数 ⇒ Single

と表す。

図 5 は生成された決定木になる。なお、履歴データには正例と負例がそれぞれ 29 : 2023 で存在し、うち 20 個の正例を下記の決定木で検出する。また過検出は 64 であり、上記の許容条件を満足する。




図 5 分節パラメータを組み合わせたルール群

各事例は決定木の根から入力され、条件に合致する枝に分類されながら T もしくは F の出力を示す葉に到達する。ここでユーザが与えた正例を T としそれ以外を負例 F とする。例えば葉 T-1 は①と②の条件を満たし、訓練事例全てを与えた場合に正例 5 個と負例 15 個がこの葉に到達する。すなわち 5 個の事例が正しく検出、15 個の負例を過検出してしまふことを示す。

図 5 の決定木の葉ノード T-1~T-4 に至るルールで検出されるイベント端点の特徴を以下に述べると共に適用結果の概要を表 2 に示す。なお、全ての分節パラメータの値が 0、すなわち特徴のない事例は分節不可能であり、T-1~T-4 に共通する条件①はこれらの事例を負例と判断する条件である。条件①により 3 つの正例が未検出となっている。

T-1 : このルールは Short_S と Short_E が 0 より大きくなる事例を検出する。この条件②は、電車の停車などで人の入れ替わりが発生した場合などの変化、すなわち、この事例を境に共存していたデバイス(人物)が立ち去り、別のデバイス(人物)が付近にやってきた可能性を示す。このルールを満たす正例は 5 つ検出された。うち C, E のイベント開始の端点は新幹線と電車に乗る時点に対応し、B, C, D のイベント終了の端点は、駅構内の移動が終了し新幹線と電車に乗る時点と新幹線を降りる時点に対応する。

T-2 : このルールは T-1 の条件を満たさず、Long_S が 0 より大きく Inc_V が 0 以上となる事例を検出する。これらの条件③, ④は長期継続するイベントが開始され、かつ周囲の人数が増加したことを表す。すなわち、デバイスが密集している空間にユーザが侵入し留まっている可能性を示す。この条件を満たす正例は 5 つ検出された。うち J, L, N のイベント開始の端点は学会セッションが開始された時点とバスに乗った時点に対応し、K, N のイベント終了の端点は委員会会議室の退室とバスを降りた時点に対応する。

T-3 : このルールは②, ③の条件を満たさず、Total_V, Same_V, Same_V2, Inc, Inc_V が 0 より小さく、Short_E が 0 より大きい事例を検出する。これら⑤, ⑥の条件は、周囲の人数が減少し短期のイベントが終了したことを表す。すなわち、この事例を境に、ユーザがデバイスの多い空間から少ない空間へ移動した可能性を示す。この条件を満たす正例は 1 つ検出された。それは D のイベント開始の端点で、新幹線を降りて駅構内を歩き出した時点に対応する。

T-4 : このルールは T-3 の条件を満たさず、Single が 0 より大きい事例を検出する。この条件⑦は、電車やバスでの停車時の入れ替わりによる新規 BDA の増加を表す。

すなわち、ユーザが複数のデバイスとすれ違うことで新規に検出される BDA が増加している可能性を示す。この条件を満たす正例は 9 つ検出された、うち、F, G, H, N のイベント開始の端点は電車と乗り降りとバスに乗る時点に対応し、A, E, F, G, N のイベント終了の端点は駅構内の移動が終了し電車に乗る時点と、電車とバスを降りる時点に対応する。

このルール集合により検出された正例と負例の数は 20 : 64 であり、ほぼ 1 : 3 の割合で正例を検出することが可能な検出ルールが得られた。しかし T-4 のルールが多くを負例を過検出しており、全体の正例検出率が 69% となった。このことは分節点を捉える特徴量を網羅できていない可能性を示している。また、13 日の検出履歴に対して、電車及び新幹線の乗車区間の停車駅を電車ダイヤと対応付けて詳細に検討した結果と、被験者が意識していなかった複数の途中駅の停車が端点候補として検出されていたことがわかった。負例から正例となったイベント端点は 4 個確認され、いずれも乗降客が多い停車駅における停車と発車であった。

3.5. 検出ルールのテストデータへの適用

前節で作成した検出ルールは訓練事例(2009/3/13 の往路)に対して過適応状態にある可能性がある。このためイベント端点の検出精度を訓練事例の復路(2009/3/15)に収録した履歴をテストデータとして評価した。テストデータに対しても訓練事例の往路データと同様に被験者が正解を与えると、正例が 18 個、負例が 623 個含まれていた。

検出ルールを訓練データとテストデータのそれぞれに適用した結果を表 2 に示す。テストデータへ適用した結果、得られた正例と負例の合計数は 11:68 であった。また、T-1 により検出された正例は 3 個で、T-4 では正例が 8 個検出され、残り 7 個の正例が未検出であった。T-1 に含まれる正例はいずれも電車の乗り降り時に与えたイベント端点であり、訓練データで与えたイベントと同様の特徴を持つイベント端点候補が検出された。また T-4 に含まれる正例も同様に訓練事例で与えたイベント端点と同様な特徴を持っており、訓練データと似たような特徴を持つイベント端点を検出することができ、全体の正例検出率は 61% となった。このことより、作成した決定木は、訓練事例に類似する事例に対しては訓練事例に近いパフォーマンスが得られることが示された。今後、種々のパターンを含む訓練事例を用いて分節パラメータの網羅性を高める為に検出できるイベント端点のバリエーションを増やす必要がある。

表 2 検出ルールの精度評価結果

訓練データ (2009/3/13)	T(正例) : 29		F(負例) : 2087	
	正解(T)	未検出(F)	過検出(T)	正解(F)
	20	9	64	2023
	69%	31%	3%	97%
テストデータ (2009/3/15)	T(正例) : 18		F(負例) : 623	
	正解(T)	未検出(F)	過検出(T)	正解(F)
	11	7	68	555
	61%	39%	11%	89%

4. おわりに

本研究では、ユーザの周囲に存在する Bluetooth 機器から得られる BDA の検出履歴を用いて、分節パラメータを考案・選択し、検出履歴のイベント候補を抽出する検出ルールを生成し、他の検出履歴で検出ルールを適用し評価した。結果、似たような特徴を持つ検出履歴に対してはイベント端点候補を検出するルールが生成できることがわかったが、分節パラメータの不足が示された。よって違った分節パラメータを提案しつつ、より一般性かつ信頼性のあるルール生成アルゴリズムの開発が必要になる。また、検出ルールによって検出されたイベント候補の端点をユーザに提示し、ユーザとのインタラクションに基づく検出ルール学習を行う必要もある。今回、出張というある意味特殊な事例を用いたが、より日常的なイベントは周期的に繰り返したり、同じ人物や機器に近接したりするという特徴があると考えられる。このような日常イベントには複数日程に渡る検出デバイスの一致を考慮するのが有効と考えられる。このような点も考慮に入れながら適用場面を拡大すると共に枠組みの完成度を高めたい。

謝辞

京都大学大学院情報学研究科の中村聡史氏には BDA 検出・記録ツールを開発・提供頂いた。ここに記して感謝する。

参考文献

- [1] http://home.dei.polimi.it/matteucc/Clustering/tutorial_html/kmeans.html#macqueen
- [2] Lawrence R, Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. Proceedings of the IEEE, Vol.77, February 1989, pp.257-286(1989-77).
- [3] Ashbrook,D ,Starner,T. Learning significant locations and predicting user movement with GPS. In International Symposium on Wearable Computing, Seattle, WA, October 2002. pp.101-108(2002).
- [4] 瀬古俊一, 西野正彬, 青木政勝, 山田智弘, 武藤伸洋, 阿部匡伸. 誤差情報を考慮した同行判定手法. 情報処理学会研究報告-UBI, Vol.2008, No.110, pp.65-72(2008-110).
- [5] Petteri Nurmi, Sourav Bhattacharya. Identifying Meaningful Places:The Non-parametric Way. Proc. Pervasive 2008, Springer LNCS5013, pp. 111-127, 2008.
- [6] Xuehai Bian, Gregory D. Abowd, and James M. Rehg. Using Sound Source Localization in a Home Environment. Proc. Pervasive 2005, Springer LNCS3468, pp. 19-36, 2005.
- [7] Ryan Aipperspach, Elliot Cohen, and John Canny. Modeling Human Behavior from Simple Sensors in the Home. Proc. Pervasive 2006, Springer LNCS3968, pp. 337-348, 2006.
- [8] 山根隼人, 長尾確. AcTrec : 行動履歴を用いた個人行動支援. 情報処理学会第 66 回全国大会-IPSJ66, 3U-8, 2004.
- [9] Timothy Sohn, Alex Varshavsky, Anthony LaMarca, Mike Y. Chen, Tanzeem Choudhury, Ian Smith, Sunny Consolvo, Jeffrey Hightower, William G. Griswold, and Eyal de Lara. Mobility Detection Using Everyday GSM Traces. Proc. Ubicomp 2006, Springer LNCS4206, pp. 212-224, 2006.
- [10] J.R.Quinlan 著, 古川 康一監訳. 「AIによるデータ解析」. トップラン (1995).
- [11] 新井イスマイル, 広瀬崇宏, 藤川和利, 西尾信彦, 砂原秀樹. Bluetooth デバイス存在検出手法の考察. マルチメディア, 分散, 協調とモバイル(DICOMO2008)シンポジウム論文集, pp.1504-1509, 2008.