

# 無線 LAN アクセスポイントへの検索要求を用いた屋内混雑度推定手法

In-door Congestion Level Estimation Using Probe Request to Wireless LAN Access Point

中野 隆介<sup>◇</sup> 沼尾 雅之<sup>◇</sup>

Ryuksuke NAKANO Masayuki NUMAO

ある場所がどの時間にどれだけ混雑しているか、という混雑情報はその場所の事業者にとっても利用者にとっても有益である。本論文では混雑度推定手法として、近年普及してきた無線 LAN 搭載モバイル端末に着目する。無線 LAN 端末は、周辺のアクセスポイントを検索するために不定期にプローブ要求をブロードキャストしている。この信号は端末が自然に送出するものであり、端末の特別な操作や事前の準備は必要ない。本論文では、この信号を利用し無線 LAN 信号のキャプチャ機器を設置するだけで混雑度の推定が行えるシステムを提案する。実際に鉄道列車内と大学の教室で実験を行い、鉄道列車内では信号から抽出した特微量を用いて 5 クラスの混雑度を 74.1% の精度で判別可能であることを、教室では在室人数に対して相関係数 0.86 の特微量を得られることを示した。

Congestion level data of the site is useful for the site users and owners. We focused on mobile Wireless LAN devices for congestion level estimation. Wireless LAN devices send the probe requests for scanning access point. Devices transmit it automatically, so users does not need to install additional systems. In this paper, we propose an in-door congestion level estimation method using mobile Wireless LAN devices. We reported experimental results in the train and classroom.

## 1. はじめに

ある場所がどの時間にどれだけ混んでいるか、という混雑情報はその場所の利用者にとっても事業者にとっても有用である。例えば、鉄道の混雑度（乗車率）を広く収集し分析を行えば空いている電車を優先的に検索する路線検索システムを作ることができると、店舗で混雑度（来客者数）を収集すれば、来客者のうち何人が実際に商品を購入したかという分析を行うことができる。混雑度推定には測定者が目視測定を行う方式 [7] や、画像処理を用いた方式 [10] などがあるが、本論文では近年普及してきたモバイル無線 LAN 端末に着目し屋内混雑度を推定する手法を提案する。

<sup>◇</sup> 学生会員 電気通信大学大学院情報理工学研究科博士前期課程  
rsk.nakano@gmail.com

<sup>◇</sup> 正会員 電気通信大学大学院情報理工学研究科  
numao@cs.uec.ac.jp

無線 LAN 端末は、周辺のアクセスポイントを検索するために不定期にプローブ要求をブロードキャストしている。この信号は端末が自然に送出するものであり、端末の特別な操作や事前の準備は必要ない。この信号から混雑度を推定することができれば、無線 LAN 信号のキャプチャ機器を設置するだけで混雑度の推定が行えるシステムを実現できる。本論文ではモバイル端末が送出するプローブ要求から混雑度推定を行うシステムを構築することを目的とする。

## 2. 関連研究

無線 LAN クライアントがネットワークに接続し通信可能な状態になるには、アクセスポイントのスキャン、認証、アソシエーションの 3 ステップを踏む必要がある [3]。スキャンにはパッシブスキャンとアクティブスキャンの 2 種類がある。パッシブスキャンはアクセスポイントが一定間隔で送信しているビーコンフレームを受信し、そこからアクセスポイントに関する情報を入手する。アクティブスキャンは周辺のアクセスポイントへプローブ要求フレームをブロードキャストし、アクセスポイントからプローブ応答フレームを受信し情報を入手する。プローブ要求フレームのフォーマットを図 1 に示す。



図 1: プローブ要求フレームのフォーマット。文献 [3] より引用。

プローブ要求フレームには送信元端末の MAC アドレスが含まれている。Interlink Networks のテクニカルレポート [5] ではアクセスポイントに接続していない無線 LAN カードが送出するプローブ要求を用いて端末を発見、追跡可能であることが示されている。また、阿瀬川ら [6] はプローブ要求を用いてアクセスポイント側で端末の位置推定を行う際に問題となる RSSI の変動から生じる位置推定誤差について議論している。本論文は端末の位置推定そのものではなく、位置推定後の結果の集約を中心に議論する。

## 3. 想定環境

本論文では、混雑度を調査したい場所のことを観測場所と呼ぶ。観測場所とはある空間の一部であり、観測場所とその他の空間とを分ける境界  $B$  が存在する。いま空間上を移動する人  $P$  が居たとき、 $P$  が観測場所の外から境界  $B$  を越えて観測場所へ移動していくことを  $P$  が入室したと言い、 $P$  が  $B$  を超えて外へ移動していくことを  $P$  が退室したと言うこととする。時刻  $t$ において観測場所内にいる ( $t$  より前の時刻に入室してまだ退出していない) 人の数のことを在室人数  $N(t)$  と呼ぶ。このとき、観測場所の混雑度  $C(t)$  を、時刻  $t$  によって変化する在室人数  $N(t)$  と比例した量として定義する。

混雑度  $C(t)$  は必ずしも在室人数である必要はなく、「空いている」「混んでいる」等の順序付きの質的な量でも良い。時刻  $t$  は連続値ではなく離散値とする。この時刻  $t$  の分解能の大きさは混雑度推定手法を適用するユーザが決定する。この分解能を  $rt$  と呼ぶ。分解能  $rt$  が大きいほど混雑度推定は容易になる。本論文では混雑度推定を機械学習問題に帰着し、推定に用いる特徴量の計算手法を提案する。

また、一度の観測の単位を系列と呼ぶことにする。一つの系列は一度観測を開始してから終了するまでに観測したデータ列を示す。混雑度の計算は一つの系列の観測を終了する度にバッチ処理で行い、リアルタイム計算は本論文では扱わない。本論文で扱う混雑度は、系列毎に独立で計算し、以前の系列には影

響されないと仮定する。加えて、系列が切り替わるタイミングで観測場所の在室人数が一度ゼロになると仮定する。例えば、店舗の場合は一日の営業時間を一つの系列として、列車の場合は始発駅から終点駅までを一つの系列とすればこの仮定を満たせる。

本論文では混雑度の推定精度をより向上させるため、観測場所を3つの種類（表1）に分けて議論する。

表 1: 観測場所の種類

|        | 入退室制約あり | 入退室制約なし |
|--------|---------|---------|
| 場所移動あり | 電車型     | -       |
| 場所移動なし | 映画館型    | 公園型     |

場所移動のありなしは観測場所が地理的に移動するかどうかを示している。ここでの移動とは境界の平行移動のみを許す。例えば鉄道の列車の車両内を観測場所とするなら、境界は各車両の外壁であり、列車の運行に合わせて平行移動している。このケースは場所移動ありのクラスになる。鉄道のホームを観測場所とするなら、その境界は移動しないので、場所移動なしのクラスになる。公共交通機関を観測場所とするなら多くは場所移動ありのクラスになる。

入退室制約のありなしは、人の出入りが時間によって制限されているかどうかを示している。具体的には鉄道の車両内は駅の停車中でなければ乗り降りできないため、入退室制約がある。公園や店舗などの場所では人の出入りが自由に行えるため、入退室制約はない。直感的には、観測場所のドアが全て閉まる状態が存在するのが入退室制約ありで、ドアが常に開いている観測場所は入退室制約なしになる。つまり、ある時間内で在室人数の変化がないと保証された場所が入退室制約ありのクラスになる。

入退室制約は以下の式で表現できる。観測場所に、その場所内外を移動できるただ1つの仮想的なドアがあったとする。時刻  $t$  の観測場所の在室人数を  $N(t)$  とする。時刻  $tc_i$  から時刻  $to_i$  までドアが閉まっている間に一度も開くことはないとすると、その間  $N(t)$  は一定なので、入退室制約  $T_{door}$  は間隔  $(tc_i, to_i)$  の集合だと考えることができ、

$$T_{door} = \{(tc_i, to_i) \mid tc_i \leq t < to_i, N(t) = \text{const.}\} \quad (1)$$

と表現できる。以降の議論の簡単化のために、 $tc_i < tc_{i+1}$  を満たすとする。この式から、ドアが開いている時間は  $to_i$  から  $tc_{i+1}$  まで、閉まっている時間は  $tc_i$  から  $to_i$  と表現できる。

入退室制約がある場合は、ドアが閉まっている時間のみを混雑度推定の対象とする。一般に入退室制約が存在する環境では、ドアが開いている時間よりも閉まっている時間のほうが長く、ドアが閉まっている時間帯の混雑度情報のほうが有益である。また、そのような環境ではドアが開いている時間帯の人の出入りが非常に激しく、混雑度の正解データを作ることが難しい。そのため入退室制約がある場合はドアが閉まっている時間  $tc_j$  から  $to_j$  のみの混雑度を対象とする。

## 4. 提案手法

混雑度推定手法は、位置推定、端末選択、入退室時間補完、特微量計算からなる。

### 4.1 位置推定手法

プローブ要求は広い範囲から受信する。この受信エリアは観測場所より大きいため、プローブ要求を送出した端末が観測場所の中にいるのか外にいるのかを位置推定する必要がある。

### 4.1.1 場所移動ありの場合

観測場所が移動しているのだから、観測場所内にいる端末も同じく移動していて、観測場所外にいる端末は移動していない。つまり、移動中にもかかわらず観測し続ける端末は場所内にいたと位置推定を行える。この推定のためにはいつ移動中かを知る必要があるが、これには入退室制約が利用できる。場所移動ありの場合の入退室制約とは移動中・停止中の時刻を示す時刻表とほぼ等価である。

また、位置推定の簡単化のために、ひとつの系列中で端末は一度しか観測場所の内外を移動しないと仮定する。例えば鉄道の場合、ある列車を駅 A で降車した端末が再び駅 B で乗車することはない、とする。この仮定により、ひとつの系列中の端末の位置は時系列で計算する必要がなくなる。

以上から、場所移動ありの場合の位置推定アルゴリズムが求まる。ある系列でプローブ要求を観測している時に、全ての端末  $D_k$  毎にその端末をはじめて受信した時刻  $ts_k$  と最後に受信した時刻  $te_k (\geq ts_k)$  を記録しておく。 $to_i < ts_k$ かつ  $te_k \leq tc_{i+1}$  のとき、端末  $D_k$  は入退室可能の状態のみで受信しており、移動中には受信していない。ここから  $D_k$  は観測場所の外側にいたと位置推定が行える。

また、 $tc_i \leq ts_k$ かつ  $ts_k < to_i$  のとき、 $D_k$  は入退室不可（移動中）に受信した端末となる。このとき、系列内で端末を受信していた時間  $\delta_k = te_k - ts_k$  を定義し、 $\delta_k < dt$  なら観測場所の外側にいたと位置推定する。鉄道を例として考えると、 $\delta_k$  が大きい端末は列車と一緒に移動していて、同じ列車内にいると推定できるので観測場所内にいたとする。 $\delta_k$  が小さい端末は移動中の列車からは短い時間しか観測できない、つまり沿線にいる端末だと推定できるので観測場所外にいたとする。この判定に用いる閾値  $dt$  は移動の平均速度から計算する。観測場所が平均秒速  $v$  [m / s] で移動している時、観測機器の 100m 前後まで受信できるのだから、移動中に観測場所の外から最大  $200/v$  秒の間受信することがある。よって  $dt = 200\alpha/v$  とする。 $\alpha$  は安全係数で、2から5程度を設定する。この手法によって場所外にいると推定されなかつた端末全てを場所内にいたとする。

この手法の利点は、位置推定を行うのに電波受信強度 (RSSI) を必要としない点である。送信元端末によって送出電波強度は異なるため、RSSI を利用する際はその個体差を吸収するモデルを構築しなければいけないが、この手法ならば送出出力が異なる端末であってもそのまま位置推定を行える [9]。

### 4.1.2 場所移動なしの場合

無線 LAN を用いた通常の位置推定手法である、電波強度を用いた手法を用いる。本手法では Scene Analysis のアプローチを採用する。多様なモバイル端末を位置推定する際の問題として、各端末の電波送出出力が異なることが挙げられる。本論文では Kjærgaard ら [4] が提案している RSSI 比を用いて機械学習を行い、位置推定を行う。

### 4.2 端末選択

以上の手法で受信した端末が観測場所内外にあるかを判定できるが、観測機器で受信できる端末は場所内に存在する全ての端末の良いサンプリングとなっているかどうかわからない。各モバイル端末の Wi-Fi 機能がオンになっていないと受信できない上、端末毎にアクティビスキャンの挙動も異なるためである。そのため、受信できる端末は全端末の偏りのあるサンプリングになっていると考えられる。

そのためこのステップで受信した全端末から一部を選択する。その際の選択の基準としては、

- 端末のベンダーによるもの
- プローブ要求の送出間隔によるもの

を用いる。

ベンダーによる選択では、MAC アドレスの Vendor OUI を用いてベンダーが特定のもの（例えば Sharp や Intel）の端末のみを利用するようにする。ベンダー名はその MAC アドレスが付与された端末の製造業者名を示す。Vendor OUI とは、MAC アドレスの上位 24bit の値で、このビットフィールドと実際のベンダー名が対応している。対応表は IEEE が管理しており [1]、誰でも参照できる。

ベンダーによる選択を用いる理由は、同一ベンダーの製品ではアクティブスキャンの挙動も似ていると考えられるためである。また、ベンダー名からどんな端末か予測できるものもあり、モバイルでないと予想できるものを除くのにも役立つ。例えば、ベンダーが Epson の端末は恐らく無線 LAN 内蔵プリンタを示していて、それはモバイル端末ではないので混雑度推定にとってはノイズとなる。

送出間隔による選択では、各端末のプローブ要求の送出間隔の中央値を用いて、その中央値が一定値以上の端末のみを利用するようとする。送出間隔が短ければ短いほどその端末の入退室時刻は予測しやすく、長ければ長いほど予測しにくい。そのため、送出間隔が短い端末のみを用いた方が推定結果がよくなると予測できる。

本手法適用の際には、ベンダーと送出間隔の 2 軸で選択を行い、もっとも良い組み合わせとなる選択手法をヒューリスティックに決定し、その手法を利用する。

#### 4.3 時間補完アルゴリズム

以上で得られたデータから各端末の入退室時刻を補完する。

##### 4.3.1 入退室制約あり

入退室制約がある場合、その制約を用いて時間補完を行うことができる。観測場所の中にいると判定された端末について、その端末が入退室不可能の時間に退出することはできない。よって、その端末  $D_k$  の  $ts_k$  と  $te_k$  が入退室可能時間に含まれていない時、その近くの入退室可能時刻まで室内にいたと推定することができる。つまり、 $tc_i \leq ts_k$  の時、 $\max(tc_i)$  を  $D_k$  の入室時刻に、 $te_k \leq to_i$  の時、 $\min(to_i)$  を  $D_k$  の退室時刻とする。

##### 4.3.2 入退室制約なし

入退室制約がない場合、端末は自由に観測場所を出入りすることができる。この場合の時間補完アルゴリズムは複数考えられる。

**PULSE** 最も単純な補完アルゴリズム。位置推定を行い、中に入ると判定された時刻のみ在室していて、それ以外の時間は退出していたとする。プローブ要求の送出間隔が計算したい混雑度の時間分解能より小さい端末には非常に有効だと考えられる。

**MEDIAN** 送出間隔の中央値を用いて補完を行うアルゴリズム。プローブ要求の送出間隔の中央値を  $m$  秒とすると、ある時刻で観測場所内にいると判定されたなら、その時刻の前後  $m$  秒まで在室していたとする。

**ALLDAY** 端末をはじめて受信した時刻  $ts_k$  から最後に受信した時刻  $te_k$  まで在室していたとする。端末の途中退室が無い場合に有効なアルゴリズムだと考えられる。

これらのアルゴリズムは端末選択の仕方によって有効なものが変化する。ここでのアルゴリズムも混雑度推定結果を見ながらその観測場所に適した物を選択する。

#### 4.4 特微量計算

以上で混雑度を推定する各時刻  $t$  につき、その時刻  $t$  に端末が観測場所に存在していたかが求まる。ここから、各時刻  $t$  に何個の端末が観測場所に存在していたかを計算する。ここから時系列の端末数データが得られる。この端末数は人数に比例する量になっていると考えられるため、この量を特微量とし機械学習を行う。求める混雑度が在室人数の場合は単回帰を、質的データの場合はクラス分類を用いる。

混雑度推定の精度を更に向上させたい場合には、時間帯や曜日などの追加の特微量を用いることができる。しかし、これらの特徴を用いると学習モデルが学習した観測場所に強くフィットしちぎてしまう過学習の問題が生じる。学習モデルの汎用性を重視する場合には端末数のみを特微量として用いる。

#### 5. 評価実験

提案手法の有効性を確認するため評価実験を行った。実験は電車型の混雑度推定を鉄道車両内で、公園型を大学の教育用計算機室で行った。映画館型は公園型に入退室制約を加えたパートナーであり、公園型よりも明らかに簡単なので実験は省略する。

##### 5.1 電車型の混雑度推定

混雑度は以下の 5 クラスとした。これは NAVITIME の電車混雑リポート [2] を参考にした。この混雑度の正解データは目視で収集した。

- Level1 [座席が半分以上空いている]
- Level2 [座席に座るスペースがある]
- Level3 [座席が埋まり座れない]
- Level4 [座席前が立つ乗客で埋まる]
- Level5 [ドア前が立つ乗客で埋まる]

また、入退室制約は乗車中に手動で駅到着時刻、発車時刻を記録し利用した。

データは鉄道は西武池袋線、京王新宿線、東京メトロ有楽町線の 3 路線で 35 の列車に乗車し収集した。データの一連は各列車に乗車してから後者するまでとした。

##### 5.1.1 端末選択結果

予備実験を行ったところ、列車内で受信する端末としては Apple (iPhone, iPad, Macbook) がもっと多く、次に Intel (ノート PC)、Sharp (IS シリーズの Android) となった。そこでベンダーによる選択はこの上位 3 つだけの場合と全てを使う場合の 4 種類で行うこととした。平均送出間隔は最小 10 秒から 2 倍ずつ増加させ選択を行った。端末選択の良さの評価値として、混雑度を 1~5 の数値で表して端末数との相関係数を用いた。選択手法の違いによる相関係数の変化を表 2 に示す。

もっとも良い相関係数が得られたのはベンダーを Apple のみ、送出間隔を 80 秒以下とした場合で、相関係数 0.74 を得た。

##### 5.1.2 混雑度推定結果

上記で求めた選択手法を用い、クラス分類を行った結果を表 3 に示す。全体の分類精度は 74.1% となった。クラス分類器は RBF カーネルの Support Vector Machine を用い、5-Fold Cross Validation で評価を行った。また、1 系列分の出力例を図 2 に示す。

##### 5.2 公園型の混雑度推定

電気通信大学の教育用計算機室で実験を行った。教室には約 140 台の端末が置かれており、学生は自由にログインして利用できる。教室の外観とプローブ要求を受信するルータの設置位置を図 3 に示す。実験は 11 月第 3 週に行い、平日の 5 日間（以

表 2: 端末選択による相関係数の変化。v=X は、ベンダーが X の端末のみを用いることを、MEDIAN は MEDIAN 秒以下の端末のみを用いていることを示す。

| MEDIAN | ALL  | v=APPLE | v=INTEL | v=SHARP |
|--------|------|---------|---------|---------|
| 10     | 0.70 | 0.74    | 0.06    | 0.44    |
| 20     | 0.70 | 0.74    | 0.04    | 0.49    |
| 40     | 0.71 | 0.74    | 0.05    | 0.50    |
| 80     | 0.72 | 0.74    | -0.03   | 0.58    |
| 160    | 0.72 | 0.73    | -0.01   | 0.58    |
| 320    | 0.71 | 0.73    | -0.01   | 0.59    |
| 640    | 0.71 | 0.73    | -0.01   | 0.59    |
| 1280   | 0.72 | 0.73    | -0.01   | 0.59    |
| 2560   | 0.72 | 0.73    | -0.01   | 0.58    |

表 3: 混雑度の分類結果

| Classified as |    |     |    |    |    |
|---------------|----|-----|----|----|----|
|               | L1 | L2  | L3 | L4 | L5 |
| L1            | 26 | 2   | 0  | 0  | 0  |
| L2            | 18 | 118 | 30 | 6  | 0  |
| L3            | 0  | 4   | 46 | 14 | 2  |
| L4            | 0  | 4   | 4  | 38 | 0  |
| L5            | 0  | 0   | 2  | 2  | 24 |

降 DAY1 ~ DAY5), 9 時から 19 時までの 10 時間データを収集した。この一日分のデータを一系列とした。

また、計算機室の全端末に 1 分毎にリモートログインを行い、ログインユーザを記録した。観測場所の教育用計算機室という性質上、ログインユーザ数は在室人数とほぼ等しいと考えられるため、以降はログインユーザ数を在室人数として扱う。

### 5.2.1 位置推定の実験結果

以下の 4 つの端末を保持して現在位置を記録しながら計算機室の内外でアクティビスキャンを行い、データを収集した。

- Apple iPhone 4S (iOS 6.0.1)
- Samsung Nexus S (Android 4.1.1)
- Sony Ericsson Xperia SO-01b (Android 2.3)
- Sharp IS03 (Android 2.1)

受信したプローブ要求から位置推定を行った。結果を表 4 に示す。計算機室の内外の位置推定精度は 76.9% となった。

表 4: 計算機室の内外の位置推定結果

| Classified as |     |     |
|---------------|-----|-----|
|               | out | in  |
| out           | 123 | 86  |
| in            | 59  | 346 |

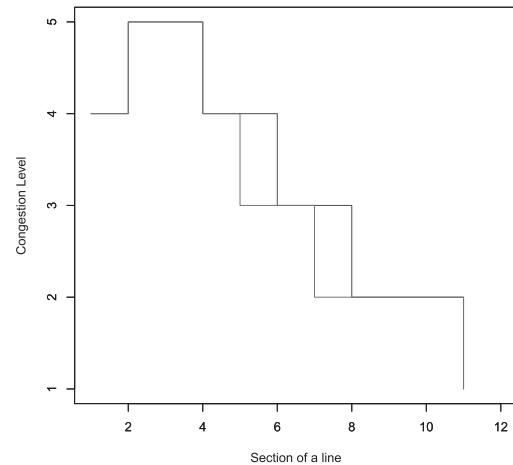


図 2: 1 系列分の出力結果例。停車駅間毎に真の混雑度（青線）と推定混雑度（赤線）の変化を示している。

### 5.2.2 端末選択結果

公園型では入退室制約が利用できないため、混雑度推定するためには端末選択手法と補完アルゴリズムの 2 種類を決定しなければならない。そのため、まずベンダーによる選択と補完アルゴリズムとの組み合わせで評価を行った。ベンダーによる選択では、計算機室での受信数が多い上位 4 ベンダーをそれぞれ用いる場合と全て用いる場合の 5 種類を用いることにした。選択の良さは端末数と在室人数の相関係数で評価した。結果を表 5 に示す。

表 5: ベンダーによる選択と補完アルゴリズムの組み合わせによる相関係数の変化

|       | ALLDAY | PULSE | MEDIAN |
|-------|--------|-------|--------|
| all   | 0.63   | 0.67  | 0.59   |
| APPLE | 0.40   | 0.81  | 0.73   |
| SHARP | 0.10   | 0.25  | 0.34   |
| INTEL | 0.12   | 0.37  | 0.31   |
| SONY  | 0.10   | 0.45  | 0.24   |

この設定では、ベンダーによる選択で Apple と、補完アルゴリズムに PULSE を用いた組み合わせが最良の結果となった。

次に補完アルゴリズムはそのまままで選択手法に送出間隔を用いた場合の相関係数の変化を表 6 に示す。

この設定では、送出間隔を 80 秒以下、補完アルゴリズムに MEDIAN を用いた場合が最良となった。次にこれらの結果を組み合わせて、選択手法をベンダーを Apple、送出間隔を 80 秒としたときに補完アルゴリズムによる相関係数の変化を表 7 に示す。

この結果から、ベンダーを Apple、送出間隔を 80 秒で補完アルゴリズムに MEDIAN を用いた場合がこの環境での最良の組み合わせとして採用する。

### 5.2.3 混雑度推定結果

上記の端末選択手法、時間補完アルゴリズムを 5 日間のデータに適用した結果を図 4 に示す。端末数と在室人数の全体の相

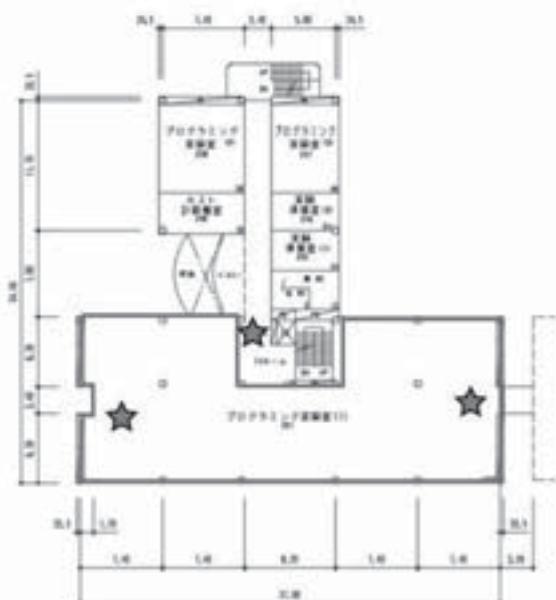


図 3: 実験環境の見取り図。赤枠で囲まれた教室が計算機室。星印がルータの設置位置。

関係数は 0.87 となった。また、各実験日の出力結果の一例（1 日分）を図 5 に示す。図 5 は DAY1 にどのように在室人数が変化したか（青線）、それに対応する端末数の変化（赤線）を示している。

## 6. 考察

### 6.1 端末選択

列車内、教室内ともに最良の選択手法はベンダーを Apple、送出間隔を 80 秒以下と求まった。表 2 から分かる通り、送出間隔による選択が結果にあまり影響を及ぼさない環境もあるので、送出間隔が 80 秒という基準は普遍的なものとは言えないが、ベンダーを Apple のみとする選択はどの環境でも有効に働くと予想できる。

この選択が有効な理由は、Apple の端末は他の端末よりもプローブ要求を送出しやすい性質があるためだと考えられる。

### 6.2 電車型の混雑度推定

全体的に高い判別性能が得られ、混雑度の誤認識もほとんどが 1 段階の間違えであるから、このような環境において本手法は有効な混雑度推定手法であるといえる。

高い判別性能を達成できた理由の一つに、RSSI を用いなかつたことが挙げられる。RSSI は周辺の環境の影響を非常に受けやすい。特に列車内は沿線からの反射波の影響を受けやすい上、常に移動しているので反射波によるノイズの生まれ方が常に変動する。このような環境では従来のノイズ削減手法（前もって反射波も含んだ学習モデルを構築しておき利用する）は適用するのが難しい。しかし本手法では、観測場所の移動と入退室制約を利用することで、RSSI を用いずに位置推定が行えた。

### 6.3 公園型の混雑度推定

相関係数は高い結果となったが、在室人数が多くなるほど端末数との誤差も大きくなっていることが確認できる。この理由は位置推定手法によるものだと考えられる。本手法では位置推定に RSSI を用いているが、RSSI は人体の影響を受ける。観測

表 6: 送出間隔による選択と補完アルゴリズムの組み合わせによる相関係数の変化

| MEDIAN | ALLDAY | PULSE | MEDIAN |
|--------|--------|-------|--------|
| 10     | 0.10   | 0.27  | 0.32   |
| 20     | 0.12   | 0.30  | 0.31   |
| 40     | 0.18   | 0.54  | 0.54   |
| 80     | 0.26   | 0.70  | 0.71   |
| 160    | 0.40   | 0.68  | 0.66   |
| 320    | 0.50   | 0.69  | 0.67   |
| 640    | 0.57   | 0.67  | 0.66   |
| 1280   | 0.63   | 0.67  | 0.65   |
| 2560   | 0.65   | 0.67  | 0.64   |

表 7: ベンダーを Apple、送出間隔を 80 秒で補完アルゴリズムを変えた場合の相関係数の変化

| v=APPLE & MEDIAN=80 | ALLDAY | PULSE | MEDIAN |
|---------------------|--------|-------|--------|
|                     | 0.83   | 0.86  | 0.87   |

場所に多くの人がいるとそれらがノイズとなり、RSSI の値に影響するので、人が多ければ多いほど位置推定精度は低くなってしまう。これを解決するのは非常に難しい。そこで他のアプローチを試みる。本手法では機械学習問題で考えているのだから、計算した端末数に加えて、その端末数がどれだけ信用できるかを示す特徴量が加えられれば精度は向上すると考えられる。そこでアクセスポイントが送出するビーコンを利用する。ビーコンもプローブ要求と同じく人体の影響を受けやすいが、必ず同じ周期で、同じ場所から送出されているという性質がある。これに関連して、人混みが発生するとビーコンの RSSI の分散が大きくなる特徴があるということが阿瀬川ら [6] の研究によつて示されている。また進藤 [8] の研究では、RSSI の大きさと人数の間には負の相関関係があることが示唆されている。この性質を利用して、特定のアクセスポイントの RSSI の分散を特徴量に加えることで、位置推定誤差の問題を軽減できると考えられる。

## 7. おわりに

### 7.1 まとめ

無線 LAN 搭載端末はアクティブスキャンを行う度にプローブ要求している。プローブ要求を利用して送出元端末の位置推定が可能である。つまりある地点でプローブ要求をキャプチャすれば周辺にいる端末数を求めることができる。その端末数は周辺人数と比例関係にあると予想されることから、プローブ要求を用いた混雑度推定手法を提案した。鉄道列車内と大学の大教室で実験を行い、有効性を確認した。

### 7.2 今後の課題

混雑時の精度向上が今後の課題である。今後はプローブ要求だけではなく、アクセスポイントが送出するビーコンなど、観測場所の周辺の電波状況をより詳細に観測し、混雑度推定に有用な特徴量を見つけていきたい。

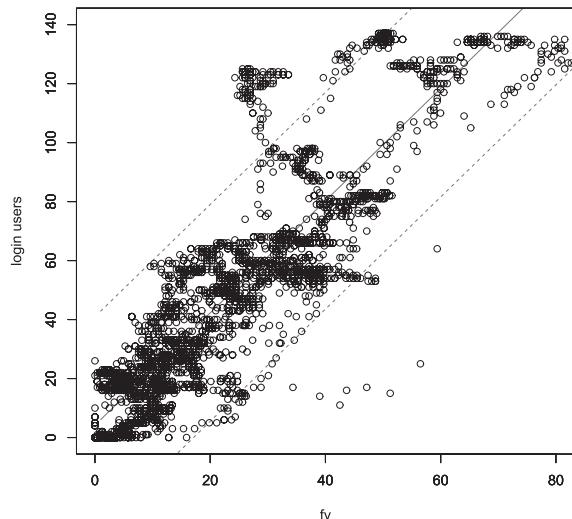


図 4: 端末数と在室人数の散布図。赤実線が回帰直線、赤波線が 95%予測区間。

### [謝辞]

本研究の一部は電気通信大学ベンチャースポーツ支援部門の補助により行われた。

### [文献]

- [1] Ieee-sa registration authority. <http://standards.ieee.org/develop/regauth/oui/public.html>.
- [2] 電車混雑リポート - navitime. <http://www.navitime.co.jp/?ctl=0171>.
- [3] M. Gast, 水野忠則, 渡辺尚, 石原進, 峰野博史. 802.11 無線ネットワーク管理. オライリー・ジャパン, 2003.
- [4] M.B. Kjærgaard and C.V. Munk. Hyperbolic location fingerprinting: A calibration-free solution for handling differences in signal strength (concise contribution). In Pervasive Computing and Communications, 2008. PerCom 2008. Sixth Annual IEEE International Conference on, pp. 110–116. IEEE, 2008.
- [5] A Practical Approach to Identifying and Tracking Unauthorized 802.11 Cards and Access Points. Technical report, Interlink Networks, 2002.
- [6] 阿瀬川稔, 田頭茂明, 荒川豊, 中西恒夫, 福田晃. 無線 lan 位置推定における誤差補正手法の一検討, ワイヤレス環境でのアプリケーション品質, p2p/アドホックネットワーク, 画像符号化, ストリーム技術, 信頼性, 一般). 電子情報通信学会技術研究報告. MoMuC, モバイルマルチメディア通信, Vol. 109, No. 122, pp. 13–18, 2009.
- [7] 清水英範. 都市鉄道の混雑率の測定方法. 第 3 回 鉄道整備等基礎調査報告シンポジウム予稿集, 2005 年.
- [8] 進藤和彦. 無線 lan の受信信号強度を用いた迷子防止アプリケーションの検討. 平成 21 年度電子情報通信学会東京支部学生会研究発表会, p. 94, 2010.

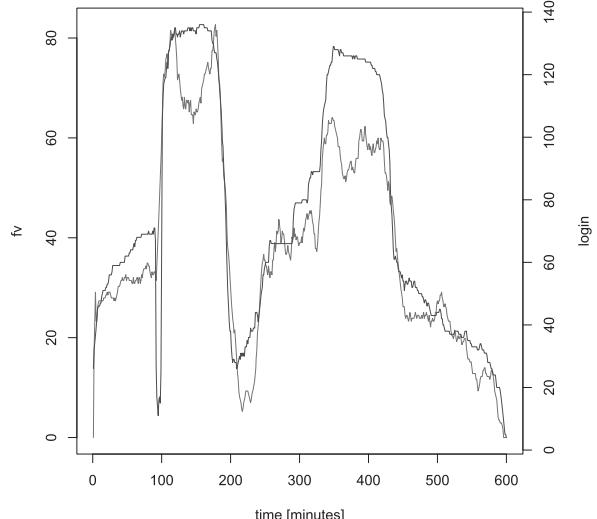


図 5: DAY1 の在室人数と端末数の変化。

- [9] 中野隆介, 沼尾雅之. 無線 LAN アクセスポイントへの検索要求を利用した鉄道車内混雑度推定. 第 4 回データ工学と情報マネジメントに関するフォーラム, 2012.
- [10] 馬場賢二, 榎原孝明, 湯浅裕一郎. 画像処理による人流計測システム. 東芝レビュー, Vol. 61, No. 12, pp. 35–38, 2006.

**中野 隆介** Ryusuke NAKANO

2013 年電気通信大学大学院情報理工学研究科博士前期課程修了。状況認識、混雑度推定の研究に興味を持つ。

**沼尾 雅之** Masayuki NUMAO

電気通信大学大学院情報理工学研究科教授。1983 年東京大学大学院工学研究科修士課程修了。博士（情報理工学）。センサネット、トレーサビリティ、情報セキュリティ等の研究・開発に従事。