

# センサルームにおける赤外線センサを用いた 人の移動・在席状況の推定と利用

江田 政聡<sup>†</sup> 中根 傑<sup>†</sup> 横山 昌平<sup>††</sup> 福田 直樹<sup>††</sup> 峰野 博史<sup>††</sup>  
石川 博<sup>††</sup>

<sup>†</sup> 静岡大学情報学部情報科学科 〒432-8011 静岡県浜松市中区城北 3-5-1

<sup>††</sup> 静岡大学情報学部 〒432-8011 静岡県浜松市中区城北 3-5-1

E-mail: †{gs10010,gs10040}@s.inf.shizuoka.ac.jp, ††{yokoyama,fukuta,mineno,ishikawa}@inf.shizuoka.ac.jp

あらまし 近年、省エネの研究が広くなされている。また、センサ機器やセンサネットワークの普及に伴い、センサを用いた人間行動推定の研究が盛んに行われている。本研究では、無線センサネットワークから得られる赤外線センサデータを用いて人の移動・在席状況を同時に推定する。そして、人の移動・在席推定の結果と温度・照度センサデータを併せて用いることで消費エネルギーのムダを発見し、省エネ化を目指す。

キーワード センサデータマイニング, 人間行動推定, センサルーム, 省エネ化

## Walk-and-presence detection using infrared sensors in the sensor room

Masaaki EDA<sup>†</sup>, Takashi NAKANE<sup>†</sup>, Shouhei YOKOYAMA<sup>††</sup>, Naoki FUKUTA<sup>††</sup>, Hiroshi MINENO<sup>††</sup>, and Hiroshi ISHIKAWA<sup>††</sup>

<sup>†</sup> Graduate School of Informatics, Shizuoka University, Johoku 3-5-1, Naka-ku, Hamamatsu-shi, Shizuoka, 432-8011 Japan

<sup>††</sup> Faculty of Informatics, Shizuoka University, Johoku 3-5-1, Naka-ku, Hamamatsu-shi, Shizuoka, 432-8011 Japan

E-mail: †{gs10010,gs10040}@s.inf.shizuoka.ac.jp, ††{yokoyama,fukuta,mineno,ishikawa}@inf.shizuoka.ac.jp

**Abstract** In recent years, energy-saving has been studied widely. In addition, with the spread of sensor machinery and sensor network, the study of context-aware or behavior detection using by these instrument has also studied. In this paper, we propose human's walk and presence detection using infrared sensors in the sensor room, and an application using the result of these detection for the purpose of energy saving.

**Key words** Sensor Datamining, Context-aware, Behavior Detection, Sensor Room, Energy Saving

### 1. はじめに

昨今、センサ機器やセンサネットワークの技術革新が著しい。それに伴い、センサ機器やセンサネットワークを用いた人間行動推定の研究が盛んに行われている。人の行動推定を行うことで行動予測・利用予測が可能となり、様々な分野で利用・発展の可能性がある。行動推定は使用するセンサ機器の種類により大きく二つに分かれる。RFIDなどの個体識別を伴うセンサによる行動推定方式と、人検知赤外線センサなどの個体識別を伴わないセンサ機器による行動推定方式である。前者は、各個人がモバイル機器などの個人を特定する端末を持つことが前提である。したがって、センサデータ取得時点で既に個人が特定されており詳細な行動推定ができる利点がある一方、端末を持つ

ていることが前提なので利用者の負担増加に繋がる恐れもある。逆に、後者の場合、人検知赤外線センサを屋内外の環境に設置し人の行動をセンシングするので利用者の負担は軽減させることができることに加え、一つのセンサネットワークを構築するだけで多数の人の行動をセンシングすることが可能となる。その一方、個体識別できないので、各個人を明確に特定することはできず、複数人の行動を正確に判別することは困難である。本研究では、そのような性質をもつ個体識別を伴わないセンサネットワークにおいて、人検知赤外線センサを用いて人の移動・在席状況を同時に推定する。

また、地球温暖化の対策として省エネルギー化の取り組みも盛んに行われている。例えば、省エネ家電の普及や、HEMS (Home Energy Management System), BEMS (Building En-

ergy Management System) などの取り組みがある。省エネ家電は家電機器単体に様々なセンサを取り付け、機器単体の消費電力の抑制を行うものである。また、HEMS や BEMS とは家庭やビルに温度・照度・ $CO_2$  センサなど環境情報を取得できるセンサ機器を配置し、エネルギーを最適に利用しようとする管理システムである。

HEMS や BEMS などの総合的なエネルギー管理システムのようなセンサネットワークは、個体識別を伴わない人検知赤外線センサとの融和性が高い。本研究では、環境情報と人の行動をセンシングできるセンサネットワーク環境下において、人の行動と環境情報との関連性から消費エネルギーのムダを発見し、省エネ化の実現を目指す。

本論文では、そのような性質をもつ個体識別を伴わないセンサネットワークにおいて、人検知赤外線センサを用いて人の移動・在席状況を同時に推定する手法を提案する。そして、人の移動・在席状況の推定結果を温度・照度センサなどとともに可視化することで、消費エネルギーのムダを発見できる可視化システムの構築について述べる。

## 2. 関連研究

### 2.1 人間行動推定とストリームマイニング

センサ機器を用いた人間行動推定の研究としては、3軸加速度センサによる行動推定や赤外線センサを用いた行動推定など、様々なセンサを使った推定手法が提案されている。Kikawaら [1] はモバイルに搭載された Bluetooth の RSSI (受信信号強度) を利用し在席推定を行い、また、池谷ら [2] は 3 軸加速度センサを用いて移動状況の推定を行った。これらは個体識別可能なセンサ機器を用いた行動推定で、本研究が対象とするセンサ機器ではない。

個体識別を伴わないセンサネットワークにおける行動推定の研究において、Honda ら [3] は赤外線センサネットワークにおける移動推定を行なっている。Honda らは隣接センサノードの情報を基に過去のノード間の移動時間を算出しノード間の移動の可能性の有無と、ダイクストラ法による最短経路決定手法によって人の移動の推定を行なっている。この方式により、複数人が同時行動することによる同時反応問題も解決している。本研究とは移動・在席状況の同時推定を行っている点が異なる。また、森ら [4] は様々なセンサ機器が設置されているセンサルームにおいて HMM を考慮した時系列クラスタリングを行い、人の行動推定を行なっている。森らは時系列クラスタリングのみによる行動推定であるが、本研究では時系列クラスタリングに分類器学習を加えることでより緻密な行動推定が可能となる。

本手法ではセンサデータのストリームマイニングを行う。ストリームデータマイニングでは、予測のためにパターン探索を行う。パターン探索の手法は多数存在する。本研究もその一つとして考えられる。Zhu ら [5] は StatStream という複数のストリームにおける部分シーケンスの相関係数を算出しパターン探索するシステムを開発した。また、Alon ら [6] は HMM の時系列クラスタリングをカメラのモーションデータに適用し、よりロバストな分類を可能とした。荒井ら [7] は複数のストリー

ムにおける、過去の遷移情報とそのときの部分シーケンスと他のストリームとの相関から、予測を行っている。荒井らの手法ではストリーム間の相関を取るとき、個々のストリームのデータをクラスタリングしその結果と組み合わせからパターン探索し、予測に繋げている。しかし、我々の手法ではすべてのストリームはクラスタリングしても同一の結果になることを前提に、すべてのストリームをまとめてクラスタリング処理している。また、パターン探索も異なる手法となっている。

### 2.2 省エネ化

HEMS や BEMS などのセンサネットワークを用いた省エネ化システムは、「可視化系」と「制御系」に大別できる。「可視化系」の研究・システムには、パナソニック電工株式会社の ECO マネシステム [8] などがある。ECO マネシステムは電力消費量を可視化することにより省エネ化を実現するシステムである。また、Google Power Meter [9] は家庭やオフィスに電力計を取り付け、その電力消費量をインターネット上でほぼリアルタイムで可視化するものである。

「制御系」の研究には、山田ら [11] の空調制御システムがある。快適性を確保しつつ、空調を制御し省エネルギー化を行うシステムである。快適性の指標には Fanger により提案された快適方程式と、その指標である PMV [11] が利用されている。Fanger の快適方程式では、温度、相対湿度、気流速度、輻射温度、着衣量、活動量をパラメータとして利用する。PMV は 7 段階で表される快適さの指標で、-3 から 3 の値を取り、マイナスに傾くほど寒く、プラスに傾くほど暑いことを表し、PMV が 0 のときに快適であるとされる。山田らのシステムは、多くのセンサを利用してそれぞれの指標を算出し、PMV 値が -0.5 ~ 0.5 に収まるように空調制御を行う。暖房運転時の調整では 0.5 に、冷房運転時の調整では -0.5 に近づけることで、快適さを保ちつつ省エネ化を行う。

本研究は、電力消費量の可視化ではなく、温度・照度センサを可視化する。電力消費量を可視化することは大変効果的であるが、安易に利用可能な温度・照度センサを用いることでシステム構築の負荷を軽減することができる。

## 3. 提案手法

本研究は、センサルームにおいて以下の移動・在席状況推定手法である  $Sc2MC^2$  を用いて移動・在席状況を同時に推定し、その推定結果とともに温度・照度センサなどのセンサデータを同時に可視化することにより、消費エネルギーのムダを発見し省エネ化を目指す。

$Sc2MC^2$  は、室内の天井に複数台のセンサノードを格子状に設置したセンサルームにおける人検知赤外線センサのセンサデータを用いて、過去のデータから人の移動・在席状況をマイニングし、そのモデルをリアルタイムのセンサデータに適用することにより人の移動・在席状況を推定する。

本章では、使用したセンサルーム、 $Sc2MC^2$  の説明、リアルタイム推定の方法についてそれぞれ詳細に述べる。また、 $Sc2MC^2$  の省エネ化への利用については 5 章で述べる。

### 3.1 センサルーム

センサルームは、森ら [4] の研究にもあるように、センサ機器を複数配置し人の行動・周囲の環境情報をセンシングする環境を言う。我々のセンサルームは、静岡大学情報学部 1 号館 4 階の一部に自律分散協調コピキタネットワークという無線ネットワーク [12] を利用して構築している。図 2 のような人検知赤外線センサ、温度センサ、照度センサの載った無線の ZigBee モジュールを天井に格子状に No New Wire で設置し、ZigBee と PLC の相互補完通信を行うことにより高信頼の通信を可能にしている。設置図は図 1 の通りで部屋の数 4 つと廊下で成るフロアの天井に 52 台のセンサノードを設置し、絶えず人の動きや部屋の気温・照度をセンシングしている。

また、人検知赤外線センサは、先に述べた RFID などの端末を携帯するタイプのセンサに比べ、1 つのセンサネットワークを構築すれば複数人の行動把握や環境情報の取得が可能なので設置コストなどの面で利点大きい。しかし、個体識別が困難な点、検知漏れが多い点などの欠点もある。検知漏れについて言うと、人が机に座っている（在席している）にも関わらず、反応しないこともしばしばあり、また、その反応傾向についても規則性があるとは言えなかった。このような環境においても移動・在席状況の推定を高精度に実現するにはそれぞれ課題がある。移動の推定においては、個体識別が困難なのでセンサの反応系列を追うなどの単純な方法は、複数人の行動を分別することはできない。具体的には、複数人が交差したとき、誰がどこに行ったのかなどの詳細な行動推定は非常に困難となる。また、在席状況の推定においては、各人の真上のセンサ 1 つを検知の有無、反応系列を用いた推定はできない。

そのため、本手法は、複数のノードの人検知赤外線センサを使い、また、多段階のストリームマイニングを行うことで、移動の推定を実現しつつ、同時に在席状況の推定を高精度に実現する行動推定手法である。

### 3.2 Sc2MC<sup>2</sup>

本手法 Sc2MC<sup>2</sup> の名前は「SingleStream Clustering to MultiStream Clustering/Classification」の略である。本手法は過去の人検知赤外線センサのセンサデータを基に移動・在席モデルの学習を行い（学習フェーズ）、そのモデルを基に現在のセンサデータにおける移動・在席状況の同時推定を行っている（推定フェーズ）。本手法は以下の 3 つの構成になっている。1) SingleStream Clustering では、単体ノードの部分シーケンスのセンサ反応傾向を分類・学習する。次に、2) MultiStream Clustering では、1) の結果を使い、同一の部分シーケンスにおける複数ノードのセンサ反応傾向の組み合わせを分類・学習する。最後に、3) MultiStream Classification では、2) の結果を使い、部分シーケンス長より長い時間幅のセンサの反応傾向を分類器学習する。

別の視点から見ると、2) の結果は短期間の移動推定と見ることができ、3) の段階で長期間の在席推定を行っているといえることができる。

以下、1), 2), 3) それぞれについて詳細に述べる。クラスタリング・分類アルゴリズムの適用には、ライセンスフリーのデー

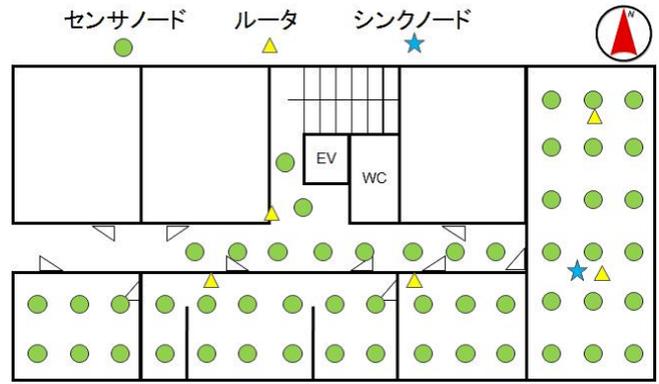


図 1 センサノード配置図

タイムニングツールである WEKA [13] を利用する。

#### 3.2.1 SingleStream Clustering

センサデータは、ノード毎に別々のストリームデータであり、 $X = (x_1, x_2, \dots, x_n, \dots)$  の値からなる半無限長のシーケンスである。最初に、このデータストリーム  $X$  に対して時間軸方向に一定の長さで分割する。この一定の長さのことをインターバル、一定の長さの区間を窓 (window) と呼び、分割されたデータストリームの一部分を部分シーケンスと呼ぶ。また、時間  $i$  から  $j$  の部分シーケンス  $P[i, \dots, j]$  は式のように表せる。

$$P[i, \dots, j] = (x_j^{i_1}, x_j^{i_2}, \dots, x_j^{i_k}), j \in [p, q] \quad (1)$$

ここでの  $[p, q]$  は対象範囲を表す。

データストリームの分割において、インターバル長は DTW (ダイナミックタイムワーピング) などの可変長の設定手法もあるが、今回は固定長のインターバルに設定した。

ここではシーケンス長の短い部分シーケンスを用いることで、部分シーケンス  $P[i, \dots, j]$  のクラスタリングを行う。この部分シーケンスを SmallSegment と呼ぶ。個々ノードにおける SmallSegment の反応列のパターンはインターバルが多くなるに従い等比級数的に増える。ここでクラスタリングすることにより、無数に存在するパターンを集約することができる。ここで使用したクラスタリングの手法は k-means で、距離  $d_{sc}(x, y)$  の定義は式 (2) のユークリッド距離により行った。簡略化のために、部分シーケンスは  $x, y$  とする。

$$d_{sc}(x, y) = \sqrt{\sum_i^n (|x_i - y_i|)^2} \quad (2)$$

例えば、部分シーケンス  $S, R, T$  が  $S = (1, 1, 1, 0, 0, 0, 1, 0, 0)$ ,  $R = (1, 1, 1, 0, 0, 0, 0, 0, 0)$ ,  $T = (0, 0, 0, 0, 0, 1, 1, 1, 1)$  で、すでに  $R$  と  $T$  がクラスタリングされておりそれぞれ別のクラスタに属しているとしたとき、 $d(S, R) = 1$ ,  $d(S, T) = \sqrt{5}$  なので  $S$  は  $T$  のクラスタではなく  $R$  のクラスタに属する。

また、本手法では滑走窓 (Sliding Window) 方式を採用することにより、SmallSegment の反応列の漏れを少なくできる。また、クラスタリングに k-means 法を使用するので、クラスタ数の設定には注意が必要となる。



図 2 センサノード

### 3.2.2 MultiStream Clustering

前節 3.2.1 の SingleStream Clustering によって、単体のセンサノードの部分シーケンスの反応列をクラスタリングしセンサ反応傾向を分類できた。ここでは、部分シーケンスの反応列のクラスタリング結果を使い、同時刻帯の部分シーケンスにおける複数のノードのセンサ反応傾向を分類・学習する。

ここでも、同時刻帯の複数センサの部分シーケンスの組合せパターンは最大 SingleStream Clustering のクラスタ数のセンサノード数乗になり膨大になるので、SingleStream Clustering と同様にクラスタリングによってパターンを集約する。使用したクラスタリングの手法は k-means で、距離  $d_{mc}(x, y)$  は式 (3) に示す、ハミング距離を用いる。ハミング距離は文字列の類似度や線形符号などで使われる類似度で、2 つのベクトルの中で対応する位置にある要素の不一致度を表すものである。  $X = (a, b, a, c)$  と  $Y = (a, a, c, c)$  のベクトル  $X, Y$  の場合、ハミング距離は 2 となる。

$$d_{mc}(x, y) = |i|x_i \neq y_i, 1 \leq i \leq n| \quad (3)$$

このように、同時刻帯の複数のセンサノードの反応傾向を分類することで、センサネットワークにおける移動の推定が可能となる。また、k-means 法におけるクラスタ数の設定には SingleStream Clustering と同様、注意が必要となる。最適なクラスタ数の設定には、移動の推定と在席状況の推定の精度の両方を考慮する必要がある。

### 3.2.3 MultiStream Classification

前節 3.2.2 の MultiStream Clustering で同時刻帯の複数のノードのセンサ反応傾向を分類できた。ここでは、複数のノードの反応傾向のクラスタリングの結果を使い、より時間幅の大きい区間における在席推定を行う。本手法ではそのより大きなシーケンス長の部分シーケンスを BigSegment と称することとする。

まず、BigSegment における SmallSegment の集合値を求める。集合値は MultiStream Clustering の結果、出力されたクラスタラベルの出現回数を用いる。

そして、そのクラスタラベルの出現回数のヒストグラムを分類学習させることにより、BigSegment 長の在席推定を可能にしている。分類学習とは教師あり学習であり、属性値からそれが属するクラスとの対応関係を学習するものである。データセットは属性値とクラスからなり、クラスは正解データを与え

る。与えられた学習データから Naive Bayes やベイジアンネットワークなどの分類アルゴリズムを用いて、データセットが正しいクラスに分類されるように分類器を構築する。

学習データのクラスは、カメラによる在席状況の検証を行い正解データを作成する。クラスタラベルの出現回数のヒストグラムを、在席状況の正解データとともに C4.5 などの分類アルゴリズムにかけ在席推定の分類器である在席モデルを作成する。また、最適な分類アルゴリズムの選択は次章の実験で検討する。

#### 3.2.4 推定フェーズ

本手法は学習フェーズと推定フェーズに分かれる。推定フェーズでは、学習フェーズで作成したモデルを用いて推定する。基本的には、推定フェーズでは学習フェーズと同じ工程を経て移動・在席状況の推定を行うが、各工程におけるマイニング部分は学習フェーズで作成したモデルを基に結果が推定される。

まず、移動・在席状況の推定を行うデータを取得し、2 つのクラスタリング工程 (SingleStream Clustering/MultiStream Clustering) を行う。このとき学習データによって作成されたモデルを使用するので、クラスタ群のセントロイドとの距離を計算し、最適なクラスタを推定する。また、最後の MultiStream Classification の工程では、学習データによって作成された分類器を使い、最適なクラスを選択し在席状況の推定結果とする。

過去に学習した移動・在席状況推定モデルを基に推定する方法は 2 つ考えられる。ひとつはある一定間隔ごと (例えば、1 時間ごと) にバッチ処理する方式、また、もうひとつはリアルタイムのストリームデータに対して逐次処理する方式である。前者はある一定期間のデータを、過去のセンサデータが格納された RDB (Relational DataBase) に問い合わせを行い、その問い合わせたセンサデータに対してバッチ処理する。この方式だと常時稼動しておかなくてよいのでコンピュータのリソースを節約することが可能であるが、今のリアルタイムのセンサデータに適用することはできない。また、後者はデータストリームに使われるストリーム型 DB である DSMS を使い、今のリアルタイムデータに対して逐次処理する。この方式だとデータ遅延の影響を受けやすいが、RDB に毎回問い合わせを行わないので効率よく、またリアルタイムデータに対して適用可能である。本論文ではリアルタイムデータに対して逐次処理するリアルタイム推定方法について述べる。

#### 3.3 リアルタイム推定

在席推定の結果を使って空調制御などの推定結果をリアルタイムで利活用したい場合、1 日分の推定をまとめて行うなどのバッチ処理は適さない。そのため、本研究ではリアルタイムに移動・在席推定を行い、省エネ化のためのフィードバックとすることを前提とする。本節では、移動・在席状況推定手法である  $Sc2MC^2$  をリアルタイムのセンサデータに適用する方法について述べる。この方式は、ストリーム型 DB である DSMS だけでなく、Java のマルチスレッドを用いてリアルタイムデータに対して逐次処理を行う。DSMS とは Data Stream Management System の略で、無限に流れ続けるストリームデータに適したデータベースである [14]。CQL (Continuous Query Language) という問い合わせを事前に登録しておき、

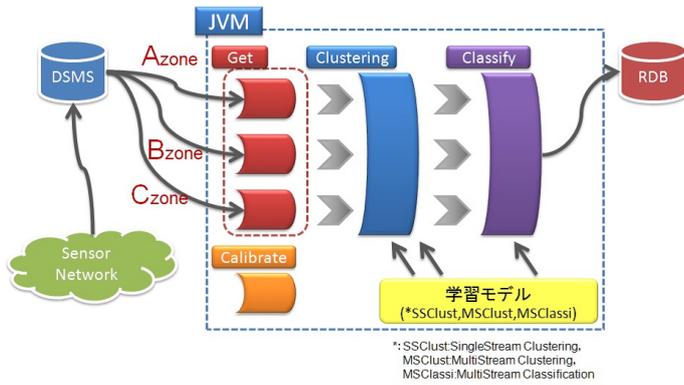


図 3 リアルタイム推定

そのシナリオに従い必要なデータを抽出し、出力する。RDBでは、分析データを一旦 DB に格納後、一括処理を行うため、データ発生から分析まで遅延が生じるが、DSMS ではデータ発生時点で、予め登録した問い合わせ CQL に従い、リアルタイムに分析可能である。また、今回使用する DSMS は日立の uCosminexus Stream Data Platform を用いた [15]。

移動・在席状況のリアルタイム推定を行う上で、本来はセンサネットワークから DSMS を介して直接、移動・在席状況の推定結果が出力されるべきである。しかし、現在の DSMS ではデータマイニングツールである WEKA の推定結果をユーザ定義関数として登録するようなことはできない。よって、本論文では、DSMS と Java のマルチスレッド処理を併用することにより、リアルタイム推定を可能にしている。

リアルタイム推定の処理の流れを図 3 に示す。リアルタイム推定は DSMS と、Get, Calibrate, Clustering, Classify の 4 種類からなるリアルタイム推定スレッドで構成されている。DSMS は推定に必要なデータ抽出し、また、移動・在席状況推定の処理単位、ゾーンごとに分割しリアルタイム推定スレッドにデータを転送する。ゾーンとはセンサネットワークのノードを処理単位に分割したもので、推定誤差を少なくするために用いる。また、移動・在席状況の推定に必要なセンサデータは、センシング時間、センサ ID、人検知赤外線センサの値である。

また、Get, Calibrate, Clustering, Classify の 4 つはそれぞれ、DSMS からデータを取得、Get スレッドで得られたデータの補正、クラスタの推定、在席推定を行う分類器学習による推定を行う。Get スレッドはゾーンごとに設けられ、図 3 では 3 つの Get スレッドが生成される。また、Calibrate スレッドはセンサデータが発生したときはデータが流れて来ないので、推定処理データの調節用としての役割を持つ。また、Clustering スレッドでは 3 つのゾーンの処理を一括処理し、 $Sc2MC^2$  の 2 つのクラスタリング工程において前節に示した通り、最適なクラスタを推定する。また、Classify スレッドでは同様に 3 つのゾーンの処理を一括で処理し、3 つの在席推定の結果を結合し RDB に格納している。在席推定に使用するモデルは過去に分類器学習したモデルを使用する。

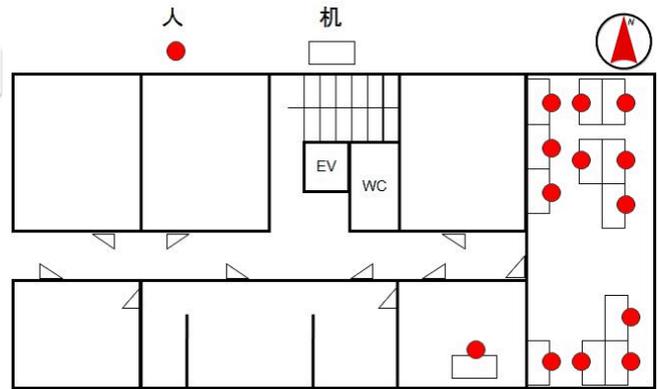


図 4 席配置図

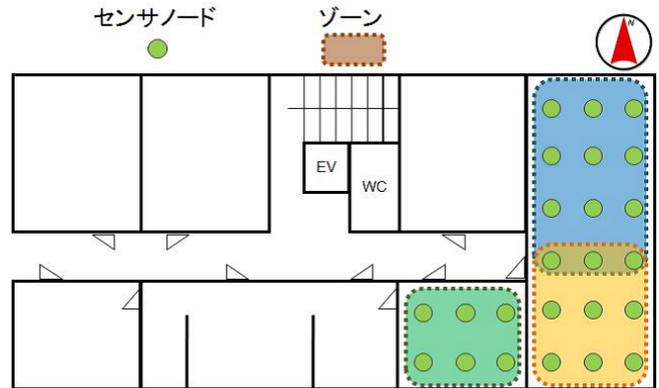


図 5 ゾーン分割

## 4. 実験

本章では、 $Sc2MC^2$  の在席推定の精度検証を行い、パラメータの最適値の決定、本手法の有用性の確認を行う。3.1 節で述べたセンサネットワークにおいて、計 13 人の在席推定を行った。実際の席配置は図 4 に示すとおりである。在席推定は天井に設置されてセンサネットワークを用いて各人に対して行う。各人の在席に影響のあるセンサノードは限られる。例えば、廊下のセンサの反応の有無は在席の有無との関係性は薄いと考えられる。逆に、推定ミスに繋がる可能性もある。よって、在席状況に影響するセンサノードのみを使用し、かつ、席のまとまったゾーンごとの在席推定を行った。図 4 における北東方向 8 人、南東方向 4 人、あと別の部屋の 1 人を分け、青、黄、緑の 3 つのゾーンに設定した。そのとき、個々ゾーンに属するセンサノードはそれぞれ 12 台、6 台、6 台となった。その様子を図 5 に示す。

実験では、青ゾーンの 8 人の在席状況の推定においてパラメータの最適値を決定し、次にそのパラメータにおいて異なるゾーンに適用した場合の在席状況の推定精度を検証する。検証方法として 10-fold cross validation (10 分割交差検定) による精度検証とする。10-fold cross validation とは入力データセット  $D$  を任意の  $k$  個のデータセット  $D_n, (n = 1, 2, \dots, k)$  に分割し、あるデータセット  $D_n$  を除いた残りの  $k - 1$  個のデータセットから分類器を生成し、 $D_n$  を評価用データとして分類精度を

表 1 パラメータの種類

パラメータ名	説明
SmallSeg 長	SmallSegment の長さ
BigSeg 長	BigSegment の長さ
クラスタ数 S	SingleStream Clustering の設定クラスタ数
クラスタ数 M	MultiStream Clustering の設定クラスタ数
在席推定アルゴリズム	分類アルゴリズム

評価する．これを  $k$  回繰り返し、全ての  $D_n$  に対して評価した平均を入力データに対する分類精度とする手法である．本実験に用いる精度は、再現率 (Recall) とする．再現率とは情報検索でも用いられる精度指標で、正解データに占める正しく予測・推定されたものの割合をいう．本実験においては、人手により作成された正解データに占める正しく在席推定されたものの割合である．

また、精度検証はあるゾーン全体の在席状況が正解であるか否かを基にしている．例えば、あるゾーンにおいて A 君と B 君が両方いるとシステムにより推定されたが A 君のみ在席している場合、たとえ A 君が在席していたことが正解だったとしてもゾーンで見たとときに不正解なので、全体の推定結果も不正解となる．

在席推定実験の正解データは、カメラによる検証を行い作成した．カメラによる検証のサンプリング間隔は 1 分とし、その時点の在席の有無が次の 1 分後までの在席の有無となる．そのため、 $Sc2MC^2$  の在席推定モデル作成データもサンプリング周期が 1 分ごとに設定されている．モデル作成には教師あり学習である C4.5 などの分類アルゴリズムを使用するので、在席推定の正解データは、教師データと精度検証のための正解データの 2 つの意味を持つ．

実験は 2010/8/6~8/22 までの 17 日間に行い、在席推定の正解データは上記の方法で作成した．モデル作成データにはその期間のセンサデータと正解データを使用した．

#### 4.1 パラメータの決定

本手法で使用するパラメータ 4 つと在席推定の分類アルゴリズムについて精度検証し、パラメータを決定する．検証する事項を表 1 にまとめた．また、パラメータの精度検証は、10-fold cross validation による方法を使う．また、結果は全体平均、全員離席、在席の平均で確認する．在席の平均とは、全員離席以外の場合の平均である．まず、SmallSeg 長と BigSeg 長について、それぞれパラメータ値の精度比較を行う．このとき、パラメータは (クラスタ数  $S$ , クラスタ数  $M$ ) = (30, 30) とし、また、分類アルゴリズムは C4.5 を使用した．結果を図 6 に示す．横軸はラベルと SmallSeg 長を表し、縦軸は推定精度である．系列は BigSeg 長である．また、ここでは秒、分、時を  $sec, min, hour$  と表記することとする．図 6 に示すように、SmallSeg 長、BigSeg 長の両方とも時間は長い方が精度が良い．したがって、SmallSeg 長は 30 秒とする．また、BigSeg 長も長くなるにつれ精度が良くなっている．短い時間幅の在席推定を行った方が実用的であり、BigSeg 長が 30 分の場合でも全体

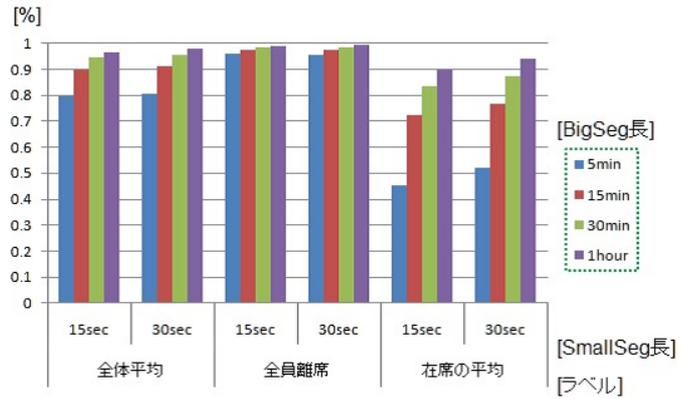


図 6 SmallSeg 長, BigSeg 長の精度検証

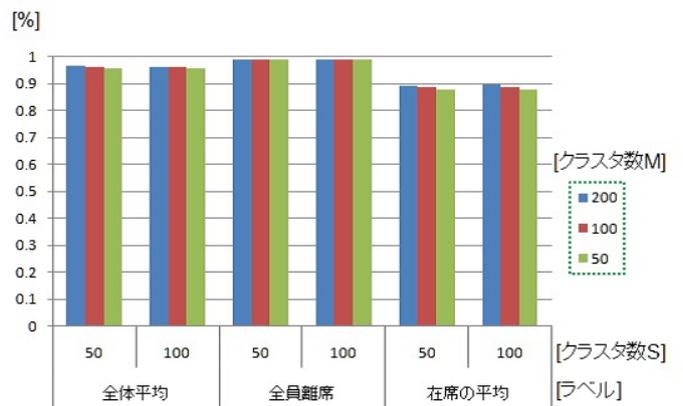


図 7 クラスタ数 S, クラスタ数 M の精度検証

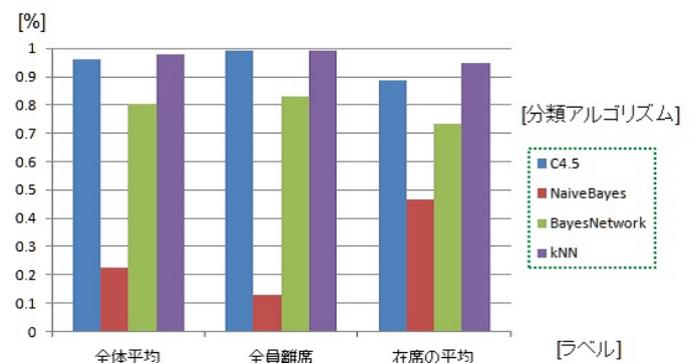


図 8 在席推定アルゴリズムの精度検証

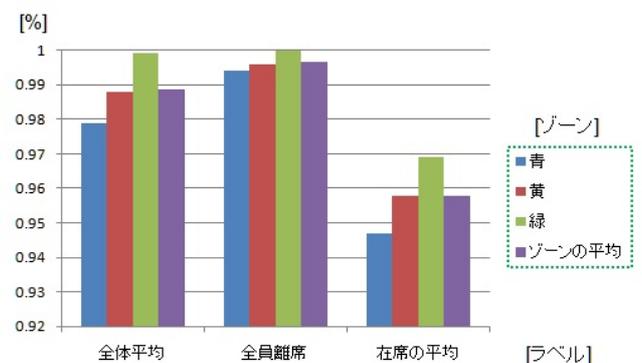


図 9 実験環境すべてにおける精度検証

表 2 決定したパラメータの値

パラメータ名	決定した値
SmallSeg 長	30 秒
BigSeg 長	30 分
クラスタ数 S	50
クラスタ数 M	100
在席推定アルゴリズム	kNN (k 近傍法), k=1

平均 95 % , 全員離席 99 % , また , 在席の平均においても 87 % の精度があることから , BigSeg 長は 30 分に設定することとする .

次に , クラスタ数 S とクラスタ数 M について , それぞれパラメータ値の精度比較を行う . このとき , その他のパラメータは (SmallSeg 長, BigSeg 長) = (30sec, 30min) とし , また , 分類アルゴリズムは C4.5 を使用した . 結果を図 7 に示す . 横軸はラベルとクラスタ数 S の値 , 縦軸は推定精度 , 系列はクラスタ数 M である . 図 7 に示すように , クラスタ数 S が変化しても精度にあまり違いが出ないことがわかった . クラスタ数 M はクラスタ数が増加するにつれ若干精度が増加した . しかし , クラスタ数を増加させるということは , 学習フェーズにおいてはクラスタリングが収束するまでの掛かる時間が増加すること , また , 推定フェーズにおいても推定時間が無駄に増加することを意味する . よって , 精度があまり変わらないのであればクラスタ数は少ない方を採用することとする . したがって , 以後 , (クラスタ数 S , クラスタ数 M) = (50 , 100) と設定する .

最後に , 在席推定アルゴリズムの精度比較を行う . 比較する分類アルゴリズムは , C4.5 , NaiveBayes , BayesNetwork , kNN (k 近傍法) である . C4.5 とは情報利得 (エントロピー) 比による決定木学習である . また , NaiveBayes とは独立性仮定とベイズの定理を用いた確率的分類器である . また , BayesNetwork とはベイジアンネットワーク分類器学習のことである . この分類アルゴリズムはベイジアンネットワークを用いて確率的分類器学習を行う . また , kNN とは , 推定対象のデータに対して , 全既知データまでの距離を計算し , その距離の無地会順に k 個で多数決をとり推定を行う . ここでは , kNN における k の値は 1 とした .

その結果は図 8 に示す . 横軸はラベルを表し , 縦軸は推定精度である . 図に示すように , kNN が一番精度が良かった . よって , これ以後 , kNN を使用する (k=1) こととする .

以上 , 決定したパラメータの値を表 2 に示す .

#### 4.2 在席推定

前節では最適なパラメータを決定した . ここでは , その決定したパラメータの値を使用し , 実験環境のすべてゾーンにおける在席状況の推定精度を検証する . 実験環境におけるゾーンとは図 5 に示す青 , 黄 , 緑の 3 つのゾーンのことである . ここでも , 前節と同様に , 10-fold cross validation による精度検証を行う .

結果を図 9 に示す . 横軸はラベルを表し , 縦軸は推定精度である . ゾーンごとの推定精度を示している . 図 9 に示すように , すべてのゾーンにおいても , 全体平均 97.9 ~ 100 % , 全員離

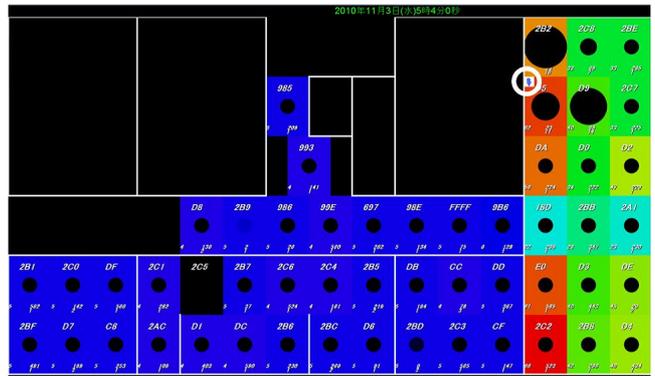


図 10 在席推定可視化システム

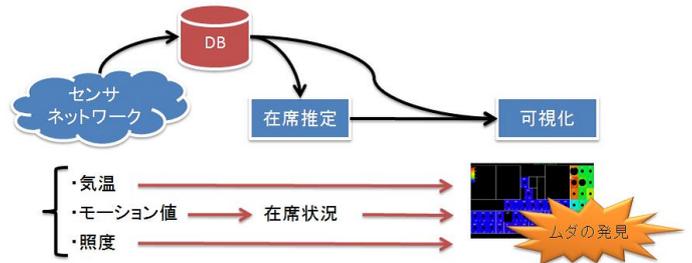


図 11 在席推定可視化システムの全体像

席 99 ~ 100 % , 在席の平均 94.7 ~ 96.6 % の高精度な結果となった . このことにより , 本手法が在席状況の推定において有用であることを示せた .

また , ここではさらに各ゾーンで若干の推定精度の違いが出たことに対して考察する . 天井に設置されたセンサノードは在席状況の推定を行う各人の真上に設置されているとは限らない . 場所によって , 人検知赤外線センサの検知に違いが現れにくい席パターンも存在することがわかった . そのことにより , 推定精度の低いゾーンでは推定精度の低い席パターンが他のゾーンに比べ多く存在したと思われる . よって , 推定精度を一定に保つには , センサノードの設置場所を各人の真上にするなどの , 確実なセンシングが必要である .

### 5. 在席推定可視化システム

本研究では , 移動・在席推定の結果と温度・照度センサの値を合わせて可視化することにより , 消費エネルギーのムダを発見し省エネ化を図ることを目指す . 今回 , 中根ら [16] が作成した可視化システムを発展させ , 人の在席状況の推定結果を同時に可視化できるように改良されている . 作成した在席推定可視化システムのインターフェイスの一例をを図 10 に示す . 中根らのシステムでは過去とリアルタイムのデータを同じ規格で閲覧できるように , データ (センサデータ , 在席推定の結果) は一度 RDB に格納し , RDB に問い合わせた結果を出力している .

この可視化システムは , Javascript の Ajax 通信を用いて非同期にセンサデータ (人検知赤外線センサ , 温度センサ , 照度センサ) を取得し , Web ブラウザに表示している . センサノードごとにセルが用意され , 利用者の好きな表示方法を選択できる .

図 10 は , 背景色が照度センサの値によって変化するように

なっている。また、同時にセルの左上の部分に在席判定の推定結果を表示し、利用者に消費エネルギーのムダの発見を促す。

在席推定可視化システムの処理の流れの全体像を図 11 に示す。

## 6. まとめと今後の課題

本論文では、センサルームにおける人の移動・在席状況を同時推定する手法である、 $Sc2MC^2$  を提案した。また、消費エネルギーのムダを発見し省エネ化を実現するための、在席状況の推定結果・温度センサ・照度センサを併せて可視化する在席推定可視化システムの構築について述べた。しかし、本論文では移動の推定の実験は行っていない。その理由は、現状のシステムではゾーンごとの状態のみしか推定することができないからである。

そのことを踏まえ、今後の課題は以下の 2 つが考えられる。より繊密な移動・在席状況の推定の実現、また、省エネ化システムにおける消費エネルギーのムダの発見の自動化である。

移動の推定に関するより繊密な推定とは、移動経路推定の推定を実現することである。我々は [17] においてひとりの人の移動を推定する手法を提案した。この時点では、複数人の移動を抽出することができなかった。しかし、本論文で述べた  $Sc2MC^2$  と組み合わせることで複数人の移動経路で推定することができると考える。また、在席状況に関するより繊密な推定とは、より短い時間間隔の在席状況の推定の実現である。我々が提案するシステムをより実用的にするためには 30 分間より短い時間間隔の在席状況の推定の実現が重要になる。

また、省エネ化システムにおける消費エネルギーのムダの発見の自動化も課題である。現在、消費エネルギー量を温度センサ・照度センサの値から類推しムダの発見につなげている。今後消費エネルギー量を計測するか、あるいは、温度・照度センサから消費エネルギー量の推定を行いたいと考える。そうすることにより、利用者自身の類推から抜け出し、より正確にムダの発見を行うことができる。

謝辞 本研究の一部は地域イノベーションクラスタープログラム グローバル型(第 II 期)「浜松・東三河地域オプトロニクスクラスター」、科学研究費補助金(B)(課題番号 22650012, 20300027)の助成による。

## 文 献

- [1] M Kikawa, T Yoshikawa, S Ohkubo, A Takeshi, Y Shiraishi, O Takahashi: "A Presence-detection Method using RSSI of a Bluetooth Device", IJIS(2009)
- [2] 池谷直紀, 菊池匡晃, 長健太, 服部正典: "3 軸加速度センサを用いた移動状況推定方式", 電子情報通信学会技術研究報告 (2008)
- [3] S Honda, K Fukui, K Moriyama, S Kurihara, M Numao: "Extracting Human Behaviors with Infrared Sensor Network", INSS(2007)
- [4] 森武俊, 野口博史, 佐藤知正: "センサネットワークと生活行動", 電子情報通信学会誌 Vol.89, No.5(2006)
- [5] Y Zhu, D Shasha: "StatStream: Statistical Monitoring of

- Thousands of Data Streams in Real Time", VLDB(2002)
- [6] J Alon, S Sclaroff, G Kollois, V Pavlovic: "Discovering Clusters in Motion Time-Series Data", Boston University Computer Science Tech. Report(2003)
- [7] 荒井健次, 白石陽, 高橋修: "クラスタ関連テーブルを利用したマルチデータストリーム予測方式", データ工学研究会 (2010)
- [8] パナソニック 電 工 株 式 会 社: "ECO マネ シ ス テ ム", <http://denko.panasonic.biz/Ebox/kahs eco/>
- [9] Google: "Google Power Meter", <http://www.google.org/powermeter/>
- [10] 山田富美夫, 米沢憲造, 花田雄一: "ビル省エネルギーに貢献する快適空調制御", 東芝レビュー Vol.59 No.4(2004)
- [11] P.O. Fanger: "Thermal Comfort: Analysis and Application in Environment Engineering", McGraw-Hill(1972)
- [12] 澤田尚志, 安部恵一, 峰野博史, 水野忠則: "無線センサネットワークを利用したセンシングデータ収集環境の構築と評価", 情報処理学会創立 50 周年記念全国大会 (2010)
- [13] Machine Learning Group a University of Waikato, "Weka3 - Data Mining with Open Source Machine Learning Software in Java", <http://www.cs.waikato.ac.nz/ml/weka/>
- [14] 森下民平: "データストリーム管理システム", CAC 技術レポート誌 SOFTECHS(2007)
- [15] 日立: "uCosminexus Stream Data Platform", <http://www.hitachi.co.jp/Prod/comp/soft1/cosminexus/products/lineup/application/sdp/>
- [16] 中根傑, 江田政聡, 横山昌平, 福田直樹, 石川博: "センサネットワークにおける大規模な可視化システムの開発", DEIM2010(2010)
- [17] 江田政聡, 中根傑, 横山昌平, 福田直樹, 石川博: "省エネルギー化を目指したセンサデータマイニング手法の検討", DEIM2010(2010)