

赤外線センサを用いた在席推定に基づく照明制御手法の提案

江田 政聡[†] 賀 新剛[†] 中根 傑[†] 横山 昌平^{††} 福田 直樹^{††}
 峰野 博史^{††} 石川 博^{††}

[†] 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

^{††} 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,gs10301,gs10040}@s.inf.shizuoka.ac.jp,

††{yokoyama,fukuta,mineno,ishikawa}@inf.shizuoka.ac.jp

あらまし 本論文では、汎用的な赤外線センサを用いた在席推定に基づく照明制御手法を提案する。赤外線センサの課題は、検知漏れや検知ミスなどの検知誤差が大きい点である。そのような環境では、高精度な複数人の行動推定を即時性のある形で行うことが難しい。本研究では、時間スケールや使用するセンサの数が異なる多段階の在席推定を行い、推定結果に基づき照明の消灯制御を行う。行動の抽象度を上げた在席状況を推定することで複数人の動きを把握でき、また、多段階に在席推定を行うことで精度と即時性の両方を担保することが可能となり、正確で素早い照明制御の実現に繋がる。在席推定などのマイニングを使わない単純な制御よりも、人の行動に則した省エネ効果の高い照明制御を目指す。

キーワード センサデータマイニング, 行動推定, 省エネ化

Masaaki EDA[†], Xingang HE[†], Takashi NAKANE[†], Shouhei YOKOYAMA^{††}, Naoki FUKUTA^{††},
 Hiroshi MINENO^{††}, and Hiroshi ISHIKAWA^{††}

[†] Graduate School of Informatics, Shizuoka University, Johoku 3-5-1, Naka-ku, Hamamatsu-shi, Shizuoka,
 432-8011 Japan

^{††} Faculty of Informatics, Shizuoka University, Johoku 3-5-1, Naka-ku, Hamamatsu-shi, Shizuoka, 432-8011
 Japan

E-mail: †{gs10010,gs10301,gs10040}@s.inf.shizuoka.ac.jp,

††{yokoyama,fukuta,mineno,ishikawa}@inf.shizuoka.ac.jp

Key words Sensor Datamining, Behavior Detection, Energy Saving

1. はじめに

近年、センサ機器・センサネットワーク技術の進歩により、それらを用いた様々なアプリケーションの研究がなされている。その一例として、HEMS(House Energy Management System)やBEMS(Building Energy Management System)などの省エネルギー化のためのスマートハウスの研究などが挙げられる[1]。

HEMS, BEMS は、家やビルにセンサネットワークを構築し、人の行動や気温、消費電力などのセンサデータから可視化や空調や照明などの電気機器の制御を行うものである。省エネ化の方法は、空調機器や照明機器などの電気機器の自動制御を行うものと、可視化などの人へ省エネ化を働きかけるものの二つに大別できる。より効果的な省エネ化を実現するには、可視化などの人へのインタラクションのみでなく、電気機器の自動

制御が欠かせない。自動制御の課題は、如何にムダな電力を使わないようにするか、つまり、不在時如何に素早く電気を OFF にするかである。赤外線センサや RFID など行動検知センサを用いて人の行動を正確に推定し、人の行動に則した素早い OFF 制御を行うことで、人が無理せずより省エネ効果の高い省エネ化を実現することが可能になる。

しかし、このような自動制御システムを構築するに当たり、大きな課題が二つある。一つは、導入面や運用面において人に掛かる負担が大きいことであり、また、もう一つは赤外線センサなどの人の行動を検知するセンサデータに検知誤差が大きくなり正確な自動制御が行えないことである。

システム導入時、センサの設置やセンサネットワーク構築において大規模な工事が必要になるシステムはあまり好ましくない。できれば、既存の機器やシステムと独立した形で、汎用的

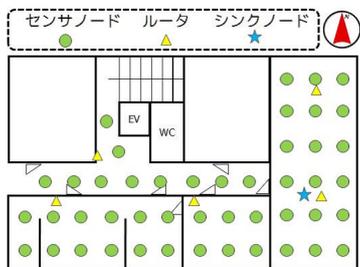


図 1 センサノード配置図

なセンサを持つ無線センサネットワークを構築することで、システム導入に掛かる既存の機器やシステムの更新を最小限に抑えて、また、一系統のセンサネットワークであらゆる電気機器の制御できる方が良い。そのため、本研究では、着座センサ [2] や扉開閉センサ [3] などの設置にコストが掛かり用途が限られるセンサの利用は考えない。また、システム運用面においても、カメラや RFID などデバイスを携帯するセンサは高精度な行動推定を可能とするが [4], [5], プライバシーへの配慮や利用者への負担の大きさを考えると、スマートハウスなどの常設システムへの利用は向かない。そのため、本研究では、最も汎用的なセンサである赤外線センサを環境に複数設置したセンサネットワークを既存の機器やシステムと独立した形で構築し、人の行動をセンシングする。

一方、赤外線センサはの課題は、次章で詳しく述べるが、検知漏れや検知ミスなどの検知誤差が大きいという課題がある。そのため、本研究では、使用するセンサや時間スケールなどの異なる多段階の、少し抽象度を上げた在席推定を行う。それにより、精度と即時性の両方を担保した在席推定が可能となる。

さらに、その多段階の在席推定結果を利用し、照明機器の消灯操作の自動制御を行う照明制御システムを構築する。一般的な照明制御のシステムは、過去 N 分間の赤外線センサの反応の有無のみを用いた単純なものである。 N の時間を短くすれば居るにも関わらず電気が消され、 N の時間を長くすれば居ないのに電気が点灯し続ける。本研究では、精度と即時性の両方を担保した多段階の在席推定結果を用いることで、より正確なより素早い消灯制御を実現し、効果的な省エネ化を目指す。

また、本論文は次のように構成される。まず、2. 想定するセンサネットワークとその課題について述べる。3. 章にて赤外線センサを用いた多段階行動推定における関連研究を挙げる。4. 章にて、まず、多段階在席推定アルゴリズム $Sc2MC^2$ に基づく照明制御手法について述べる。また、5. にて、 $Sc2MC^2$ を詳しく説明する。6. 章にて照明制御の有効性を検証する。最後に、8. 章にてまとめと今後の課題を述べる。

2. 想定するセンサネットワークとその課題

我々は、静岡大学情報学部 1 号館 4 階の一部に自律分散協調ユビキタスネットワークというセンサネットワーク基盤を利用している [6]。赤外線センサに加え、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 の通りでオフィスの数が 4 つと廊下でなるフロアの天井に高密度に 46 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。

赤外線センサは、人の動きの有無を検知する汎用的なセンサである。そのため、センサの性能に伴い、二つの課題が生じる。一つ目は、人の動きを正確に追うことができないことである。オフィスなどの狭い空間に不特定多数の動きが絡み合うような環境において、センサ間の反応順序を使って予測を用いずに推定することは難しい。また、二つ目は、人が居て動かない場合と居ない（離席）場合の区別が難しいことである。人の居るか居ないかを検知しているのではないため、PC 操作、デスクワークなどの人が静止しているようなあまり動きのない場合は瞬時に在席していると推定することはできず、長期間の反応傾向から推定する必要がある。

また、赤外線センサは検知範囲に重複のないように設置することが大変難しい。赤外線センサは円錐形の検知範囲を持つセンサであるため、検知漏れのないように高密度に設置しようする場合、どうしても検知範囲の重複は起こってしまう。

このように、赤外線センサは検知漏れや検知ミスなどの検知誤差を多く含むセンサであることがわかる。本研究では、そのような赤外線センサの課題を解決する行動推定手法を提案する。ポイントは 3 つある。

一つ目は、行動推定の対象を移動などの詳細な動きの推定ではなく、抽象度を上げた在席状況の推定することである。同一の検知範囲に複数人が通過する場合、Honda らのように、行動のヒントを与えてあげなければ複数人の行動を抽出、推定することはできない [8]。そのため、その場所に人が居るか居ないかという、抽象度を上げた在席推定を行うことで、詳細な行動は推定できないが、正確な推定を行う。

二つ目は、使用するセンサや、短期間や長期間の異なる時間スケールによる多段階の在席推定を行うことである。デスクワークなどの軽微な動きの場合、高精度な在席推定をするには複数のセンサや長期間のセンサデータを用いた推定である必要がある。また、照明制御などへの利用を考えた場合、短期間の推定も必要であるので、多段階の出力を持つ在席推定を行うことで、即時性と精度の両方を満たす推定を行う。

三つ目は、センサの反応系列を追うのではなく、各センサの個別の時系列クラスタリングを集約して推定を行うことである。赤外線センサは複数人の行動が絡むと、正確に推定を行うことが難しい。複数の赤外線センサの時系列クラスタリング結果を集約させるようなストリームマイニングの手法を取ることで、検知誤差がある程度存在しても正確な在席推定を行うことができる。そのため、センサの台数に依存せず、設置場所・センサの個数に柔軟な推定を行うことができる。

本研究では、上記の課題を解決し正確な在席推定を行い、また、さらに、在席推定に基づく照明制御を行うことで、より人の行動に則した、効果的な照明制御を実現することを目指す。

3. 関連研究

本章では、赤外線センサを用いた行動推定の研究動向について述べる。一般的に用いられている推定手法は、過去の赤外線センサの検知の有無によるナイーブな推定である。ユビテックでは、この手法によりオフィス環境の省エネ化を実現している[7]。6分間モーションを検知しなければ、その部屋の照明を消灯制御するものである。見える化などの他の効果も含めた結果ではあるが、25%の電力使用の抑制を実現している。N分間モーション検知をしなければ消灯制御するような手法は、複雑なシステムを構築する必要がなく、単純なマイコン上でも実装可能という利点がある。しかし、単純な一元的な制御であるため、「人が居るにも関わらず照明が消灯するようなこと」や、また「人が居なくなったにも関わらず照明が点灯し続ける」などの誤動作が起こりうる。本研究では、短期間と長期間のスケールを持つ多段階の推定方式を採用することにより、「人が居るにも関わらず照明が消灯するようなこと」を最小限に抑えつつ、人が居なくなったら素早く離席判定・消灯制御するような即時性の高い在席推定・照明制御を目指している。

先に述べた赤外線センサの欠点を解決して高精度な行動推定をしている研究もある。Hondaら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[8]。Hondaらは隣接センサノードの情報を基づいて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、赤外線センサの検知範囲の重複が発生するような環境においても複数人の移動を86%の高精度で推定することを可能とした。しかし、移動の目的地の場所などの情報が事前に必要となる。本研究では、提案手法の精度を向上させるために在席状況の正解データが必要となるが、一度、最適な学習を行えば、行動ごとに個別の知識を入力する必要はない。また、Hosokawarらは、ベイジアンネットワークを用いて高密度に設置した赤外線センサを用いて移動の推定を行っている[9]。検知範囲が重複し、より検知誤差の起こりやすい環境においても、単数人の移動を64%、複数人の移動を20%で推定する可能とした。本研究と類似した環境において、複数人の行動推定に課題があることがわかる。そのため、本研究では、行動の抽象度を上げた在席推定を行うこととし、複数人の動きを精度よく推定することを可能とした。また、村尾らは各部屋に1つずつ設置した赤外線センサを用いて移動経路の推定を行った[10]。本研究では、図1に示す通り高密度にセンサノードを配置し、検知誤差の多い狭い環境における人の行動を対象としている点が異なる。

4. 提案手法

本研究では、センサルームにおいて多段階の在席推定アルゴリズム $Sc2MC^2$ を用いて、マイニングを用いないナイーブな制御に比べ、誤った消灯操作など制御精度を維持した、より素早い消灯制御を実現する。使用するセンサの数や時間スケールの異なる多段階の在席推定結果を用いることで、移動などの短期間の行動と在席などの長期間の行動で別々の制御を行うこと

表 1 照明制御に用いる在席推定のパラメータ値

パラメータ名	説明	最適な値
SmallSeg 長	SmallSegment の長さ	15 秒
BigSeg 長	BigSegment の長さ	15 分
クラスタ数 S	SingleStream Clustering の設定クラスタ数	50
クラスタ数 M	MultiStream Clustering の設定クラスタ数	100
分類アルゴリズム	推定に用いる分類アルゴリズム	kNN(k=1)

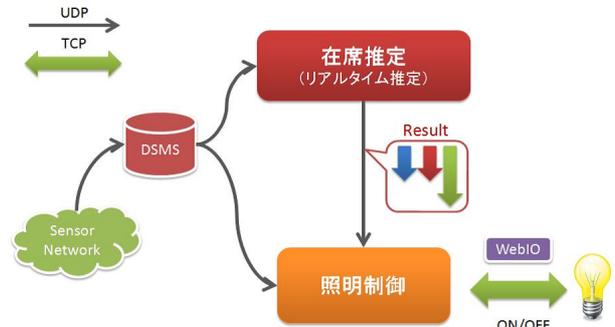


図 2 照明制御の全体像

ができるため、一元的なナイーブな制御に比べ、素早い消灯制御が可能となる。

まず、RDB に格納された過去の赤外線センサの値とカメラによる人の在席状況の正解データを基に多段階在席推定の在席モデルを事前に学習する。そして、得られた在席モデルを用いて、リアルタイムの赤外線センサの値からリアルタイムの在席状況を推定し、推定された複数の在席結果を利用し、人の離席時に照明を消灯制御することに利用する。

本システムでは、在席推定の処理を行うため、制御にデータが反映されるまでに数秒の遅延が生じる。利用者の快適性の観点から、照明の点灯制御は最も即時性が求められる。そのため、本研究では、点灯制御において、ある程度のクリーニング処理を施した生のセンサデータを持ちることとする。

また、今回、照明制御システムでは、表 1 に示す在席推定パラメータを用いることとする。

本章では、在席推定 $Sc2MC^2$ に基づく照明制御手法における照明制御機構と、在席推定結果を用いた消灯制御アルゴリズムについて詳細に述べる。また、在席推定アルゴリズム $Sc2MC^2$ の詳細については、5. 章で述べる。

4.1 照明制御機構

本研究では、Web I/O と Java マルチスレッドによる逐次処理 (リアルタイム在席推定) を用いて、リアルタイムの照明制御システムを構築した。

提案する赤外線センサを用いた在席推定に基づく照明制御システムの全体像は、図 2 に示す通りである。

リアルタイムに得られるセンサデータは、DSMS(Data Stream Management System) を介して、必要のある赤外線センサなどのデータのみリアルタイムの在席推定と点灯制御に利用される。リアルタイム在席推定では、DSMS より受け取ったデータを JMS(Java Message Service) や Java マルチスレ

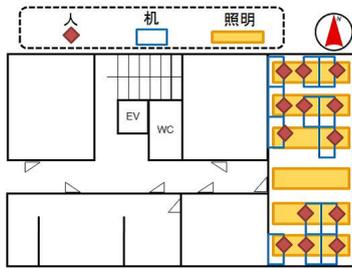


図 3 照明の区画と座席の位置関係

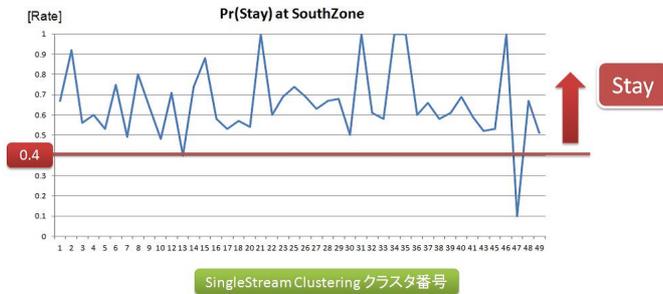


図 4 各クラスタに占める Stay の割合 (学生部屋南側)



図 5 StayAway 推定による消灯制御

ドによりリアルタイムに在席推定の逐次処理が行われる。その複数の推定結果は、ネットワーク経由で、照明機器の消灯制御に利用される。照明機器の消灯制御は、下記に示す消灯制御アルゴリズムに則り、Web I/O を介して消灯制御命令を実行する。この Web I/O とは、電源と電気機器との間に接続し電気機器の ON/OFF 制御を行うもので、TCP/IP プロトコルを介して制御を行う [14], [15]。

また、制御は区画毎に行い、実験環境では各区画 3 台ごとのセンサードを用いて制御を行う。実験環境では、6 区画に分割でき、各区画 6 本の蛍光灯の点灯/消灯制御を行う。実験環境での照明の区画と座席と位置関係は、図 3 に示す。また、消灯制御を分毎に行うこととする。電気機器の故障や利用者の快適性の観点から、秒単位で頻繁に点灯/消灯制御することは好ましくない。そのため、本研究は消灯制御を分毎に行うこととする。

4.2 消灯制御アルゴリズム

本研究では、多段階の在席推定の複数の推定結果を同時に利用し、正確で、かつ、素早い消灯制御を行う。多段階の在席推定結果を用いることで、移動などの短期間の行動と在席などの長期間の行動で別々の制御を行うことができ、一元的なナイーブな制御に比べ、素早い消灯制御が可能となる。素早い消灯制

御を行うことで、消費電力のムダを抑制することができる。

在席推定を用いた照明制御の方法として考えられるのは、静的な離席状態の検知、動的な離席イベントの検知、在席予測などが考えられる。本論文では、在席推定を用いて静的な離席状態を把握し、消灯制御を行う最もシンプルな手法である StayAway 推定による消灯制御手法について説明し、実験にてその消灯制御の有用性を検証する。また、動的な離席イベント検知による消灯制御手法については、7. 章で在席推定に基づく制御手法の応用手法として述べることとする。

本研究は、多段階在席推定 $Sc2MC^2$ の 1 段階目の最も即時性の高い 1) SingleStream Clustering と、3 段階目の最も推定精度の高い 3) MultiStream Classification を用いて消灯制御を行う。1) SingleStream Clustering は過去の学習モデルにおいて最も類似した傾向を示すクラスタを推定する。消灯制御においては、在席 (Stay)、あるいは、離席 (Away) の二値を推定する必要がある。予備実験にて過去の正解データを基に各クラスタごとに Stay/Away を決定し、その結果を基に StayAway 推定による消灯制御を行う。

4.2.1 StayAway 推定

$Sc2MC^2$ の 1 段階目 1) SingleStream Clustering では、各センサードの 15 秒間の短期間の反応傾向の推定を行う。過去の学習モデルに基づき、センサの反応傾向が推定される。推定されるセンサの反応傾向は、設定するクラスタの数を同じになる。つまり、50 個である (表 1 参照)。照明制御に利用しやすいように、過去のデータを基に予備実験を行い、在席 (Stay)/離席 (Away) の二値を出力するような処理を加える。予備実験では、在席状況の正解データを基に、クラスタに属する在席 (Stay) の割合が全体の 40 % 以上の場合を在席 (Stay) とし、また、それ以外のクラスタを離席 (Away) と推定することとした。学生部屋南側の各クラスタの全データに占める Stay の割合は、図 4 に示す通りである。図 4 に示す通り、各クラスタごとで Stay の占める割合は比較的均一である。つまり、1) SingleStream Clustering では正確に在席 (Stay)/離席 (Away) を高精度に推定することができないことがわかる。また、照明の消灯制御において重要なことは、省エネ効果を上げることと、利用者の快適性を維持することである。誤って消灯することがなくだけ少ないように照明制御を実現する必要がある。そのため、各クラスタの Stay の割合が 40 % 以上という緩い閾値を設けることで、利用者の快適性を維持する StayAway 推定を行う。したがって、逆に、在席 (Stay) 時にも、離席 (Away) と推定されることも多々存在する。

4.2.2 StayAway 推定による消灯制御

多段階在席推定 $Sc2MC^2$ の 1 段階目の最も即時性の高い 1) SingleStream Clustering と、3 段階目の最も推定精度の高い 3) MultiStream Classification を用いて消灯制御を行う StayAway 推定による消灯制御について説明を行う。

省エネにとっても、利用者の快適性にとっても理想的な消灯制御とは、人が居るときに正確に照明が点灯し続け、居なくなったら素早く照明を消灯する制御である。つまり、人の行動に則した制御を行うことが重要となる。

先ほど説明した通り、ナイーブな手法では過去 N 分間の赤外線センサの反応の有無による制御であるため、人が N 分に 1 度その場所を通過するだけで、照明は点灯し続ける。その原因は、ナイーブな手法が人の移動と在席という 2 つの概念を分けていない一元的な制御であるためである。そのため、本手法では、長期間の在席推定結果と短期間の在席推定結果の両方を用いることで、ナイーブな手法と比べ制御の正確性を維持しつつ素早い制御を実現している。具体的には、長期間の在席推定では人の移動などの短期間の行動が反映されず、また、短期間の推定では在席などの長期間の行動が反映されないため、両方を用いることで、人の行動に則した制御を行うことができる。人の移動時には素早く消灯制御され、また、在席時には、誤って消灯することのないような制御を行う。

制御アルゴリズムは、図 5 に示す通りである。消灯制御は分単位で行うため、15 分間の在席推定結果 (3)MultiStream Classification) と、過去 1 分間の 15 秒間の在席推定結果である StayAway 推定の結果がすべて離席 (Away) と推定されたとき、はじめて消灯制御を行う。

過去 1 分間で 15 秒間の在席推定結果である StayAway 推定の結果が一度でも在席 (Stay) と推定すると、照明は消えない。つまり、人が机などに居ない離席状態で移動などの短期間の行動では、1 分に一度は Stay と推定されるような動きを行う必要がある。しかし、移動などの動きの場合、赤外線センサはデスクワークに比べ反応しやすいので問題ないと思われる。

また、照明制御は区画単位で行うので、各区画に属する 3 つのセンサノードの StayAway 推定の結果を利用することとなる。照明制御の区画に属するすべてのセンサノードが離席 (Away) と推定されるとき、かつ、長期間の在席推定結果 (3)MultiStream Classification) が離席の時のみ、消灯される。つまり、61 個のすべての在席推定が離席 (Away) と推定された時、はじめて消灯される。

また、長期間の在席推定 (3)MultiStream Classification) では、15 分間で 80 % 以上在席している状態を推定するので、理論的には、15 分間の 20 % 以上つまり 3 分間以上離席状態が続くと、照明機器が消灯される。本来、消灯までに掛かる時間が 3 分間ではなく 6 分間以上 ubiteq になるよう 3)MultiStream Classification の BigSegment の長さを設定する必要があるが、今回の実験では表 1 に示す 15 分を BigSegment の長さとする。本照明制御にとって、最適な BigSegment の長さを設定することは、今後の課題とする。

在席状況の推定に強い長期間の推定と、移動に強い短期間の推定を組み合わせることで、利用者の在席時には誤った消灯を抑制しつつ、離席時には素早い消灯制御を行うことが可能となる。

また、6. 章の実験にて、照明制御の制御の正確性、制御の即時性、また、照明の点灯時間削減の省エネ効果の検証を行う。

5. 在席推定アルゴリズム $Sc2MC^2$

在席推定アルゴリズム $Sc2MC^2$ の名前は、「SingleStream Clustering to MultiStream Clustering/Classification」の略で

ある。始めに、過去の赤外線センサのセンサデータを基に 3 段階の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在席推定を行っている (推定フェーズ)。 $Sc2MC^2$ は、図 6 に示す通り 3 段階の構成になっており、それぞれ使用するセンサの数、時間スケールの異なる在席推定を行う。

1)SingleStream Clustering では、各センサの短期間 (部分シーケンス) のセンサ反応傾向を推定する。次に、2)Multi-Stream Clustering では、1) の結果を使い、短期間 (部分シーケンス) の複数のセンサ群のセンサ反応傾向を推定する。短期間の各センサの反応状況を推定することで、短期間の間に各センサの下での人の動きを捉えることができる。センサの位置関係と人の席配置との関係、一つのセンサの反応を見るだけでは検知範囲の被りなどでうまく推定することが出来なかったものが、複数のセンサの反応を見ることでより正確に推定することができる。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期間の複数のセンサ群の反応傾向を推定する。2) では短期間の推定であったが、PC 操作などのあまり動きのない動作など、在席しているにも関わらず赤外線センサが検知せず、正しく在席と推定できない場合が存在する。そのため、3) ではセンサ群の短期間の推定結果である 2) を長期間のデータを用いることで、より正確な在席推定を行う。

本アルゴリズムは簡単に表現すると、時系列クラスタリングの結果 (1) を複数のセンサ群、長期間のデータ推定にクラスタリングと分類学習を使い、拡張 (2), 3)) させた手法と言える。

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タマイニングツールである WEKA [12] を利用する。

5.1 SingleStream Clustering

ここでは、各センサの短期間 (部分シーケンス) のセンサ反応傾向の推定を行う。

センサデータは、各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、図 6 のように、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。図ではある時刻にモーションを検知した場合を 1、検知していない場合を 0 と記す。このとき、分割するセグメントは固定長とし、その部分シーケンスを SmallSegment と呼ぶこととする。DTW (Dynamic Time Warping) などセグメントを可変長とすることも可能であるが、今回 DTW は用いない [11]。

そして、固定長に切り出した部分シーケンスから特徴量を抽出し、クラスタリング手法を用いて部分シーケンスの特徴をグループ分けする。部分シーケンスの特徴量は、検知回数と検知のばらつきを用いる。検知回数とは赤外線センサの反応回数であり、また、検知のばらつきとはある検知から次の検知までの時間間隔の平均である。つまり、どれだけ検知したか、どれだけばらつきが存在したかを表す。例を示すと、ある時刻に検知した場合を 1、検知していない場合を 0 とし、各秒ごとに並べた場合、

部分シーケンス $S = (1, 1, 0, 0, 0, 1, 1, 0, 0, 1, 1, 0, 0, 0, 1)$ の特徴量は、検知回数 = 7, 検知のばらつき = $(3 + 2 + 3)/3 = 2.67..$ となる。クラスタリングには、k-means を使い、距離 $d_{sc}(x, y)$ の定義は式 (1) の標準ユークリッド距離により行った。簡略化のために、SmallSegment は x, y とする。

$$d_{sc}(x, y) = \sqrt{\sum_i^n \frac{|x_i - y_i|^2}{\sigma_i}} \quad (1)$$

また、滑走窓 (Sliding Window) 方式を用いて、反応の推移も漏れを少なくするようにした。

学習フェーズでは、過去のセンサデータを解析し学習モデルを作成する。推定フェーズでは、その学習モデルを固定しその学習モデルを基に推定を行う。学習モデルにおける各クラスタの中心との距離で一番近いクラスタを推定する。本工程より、精度は低い即時性の高い在席推定が可能となる。

5.2 MultiStream Clustering

ここでは、SingleStream Clustering による推定結果を利用し、短期間の複数台のセンサ群の反応傾向の推定を行う。

同時刻帯の複数センサ群の反応傾向を推定するため、特徴量として各センサノードの SingleStream Clustering の推定結果、つまり、所属クラスタを用い、クラスタリングによりグループ分けする。距離の尺度として、式 (2) に示すハミング距離を用いる。ハミング距離と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。クラスタリングを用いることで、膨大にあるセンサ群全体の反応傾向を大別することができる。

$$d_{mc}(x, y) = |\{i | x_i \neq y_i, 1 \leq i \leq n\}| \quad (2)$$

SingleStream Clustering と同様に、推定フェーズでの MultiStream Clustering の推定は学習モデルにおける各クラスタの中心との距離で一番近いクラスタを推定するものである。

5.3 MultiStream Classification

ここでは、2)MultiStream Clustering の推定結果を利用し、複数台のセンサ群全体における、SmallSegment 長より時間幅の大きい区間の在席推定を分類器学習を用いて行う。長期間のデータを使い、また、教師あり学習による推定を行うことで、即時性は低いが高精度な在席推定が可能となる。この時間幅の大きい区間を BigSegment と呼ぶこととする。

MultiStream Classification では、BigSegment における SmallSegment の集約値と共に、在席状況の正解データを教師データとして用い、分類器学習させる。その分類器を用いて、推定フェーズで在席状況を推定する。

BigSegment における SmallSegment の集約値として、2)MultiStream Clustering で推定された所属クラスタの出現回数を用いる。

また、教師データである在席状況は、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。赤外線センサは人を区別することができないので、図の 3 のような各人の席、正

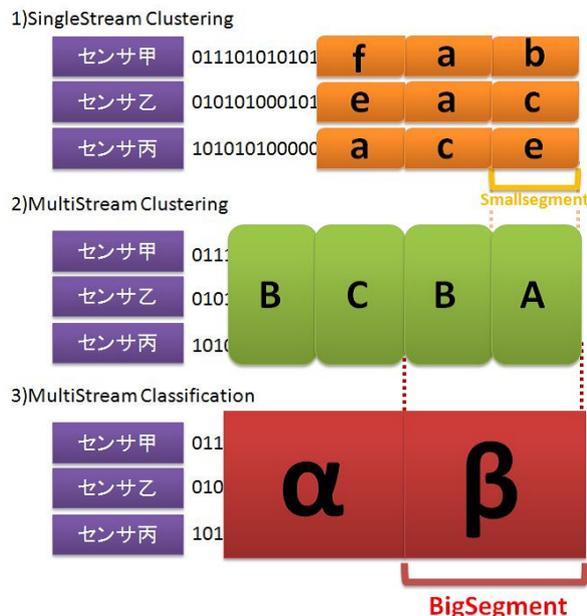


図 6 Sc2MC² 処理フロー

確には机の前に人が居るか居ないかを在席状況として用いる。固定した場所に人が居るか居ないかを推定するため、本研究の適用範囲はオフィス環境に限らない。また、ある席において過去 BigSegment 長の 80% 以上の時間が在席状態にあった場合、ある席の在席状況は「在席」とする。もし、80% 未満しか在席していなければ、ある席の在席状況は「離席」とする。センサ群の検知範囲内の全部の席の在席状況をまとめて、その時の在席状況として使用する。例を示すと、席 A, B, C について (A, B, C) = (在席, 在席, 離席) の場合、センサ群全体の在席状況を AB と表す。つまり、在席状況のパターンは、席の数を N とすると N^2 個存在することとなる。

しかし、教師データである在席状況を変えることで別の状況を推定することができる。備え付けの照明機器などは、点灯・消灯などの操作などを区画ごとに行なっている。そのような場合、区画ごとに在席推定した方が効果的である。そのため、本論文では区画ごとの在席状況を利用することとする。前者の各人毎の推定については、文献 [13] にて検証しており、本論文での検証は行わない。詳細については、文献 [13] を参照されたい。

MultiStream Classification の推定フェーズでは、過去 BigSegment 長区間において 80% 以上の在席状態を推定する。本工程により、即時性は低いが高精度な在席推定が可能となる。

6. 実 験

本章では、在席推定に基づく照明制御についての三つの観点で検証実験を行う。照明制御の精度、消灯制御の即時性、また、本手法を用いた時の省エネ効果の三つである。この三つの観点により、在席推定に基づく照明制御の有用性を、ナイーブな制御手法と比較、検証する。ナイーブな制御手法とは、 N 分間の赤外線センサの反応の有無によるナイーブな制御手法のことであり、今回、比較手法は、実際の実験環境で動作検証した 5 分

間の赤外線センサの反応の有無によるナイーブな制御手法を用いることとする。

また、検証内容について詳しく説明する。照明制御の精度の評価は、在席時の照明の点灯時間により評価する。在席時、照明が正しく点灯しているか、誤って照明を消灯していないか検証する。そして、在席時、正解データと比較し、正確に点灯していた時間を算出し、評価する。また、消灯制御の即時性の評価は、在席から離席に変わる離席イベントが起きた地点から、照明を消灯制御するまでの時間により評価する。また、本手法を用いた時の省エネ効果については、実験期間中に電気が点灯していた時間により評価する。

本実験では、シミュレーションを用いて擬似的な照明制御を行い、手法の評価を行う。シミュレーションを用いた擬似的な照明制御とは、赤外線センサのデータや人の在席状況は実際に得られたデータを用いて、制御のみシミュレーション上にて実現するものである。制御をシミュレーション上で行う理由は、実地環境では比較手法との比較が難しいからである。日や時間帯により人の在席状況、また、活動状況はまちまちである。別の日で行う場合、平等な評価を行うためには長期間の実験が必要である。制御をシミュレーション上で行うことにより、照明制御の有用性を比較的簡単に検証することができる。

また、照明制御は図3に示すように、区画単位で行うため、区画単位で評価することとする。今回、図3に示す南側1区画、3人を実験対象とし、2011/10/5～10/8までの3日間のデータを用いて検証した。また、多段階在席推定の結果は南側6個のセンサノードを用いて5人の在席推定を行った結果である。また、在席推定の正解データはカメラを用いて下記の方法で作成した。カメラを用いた静止画撮影した画像を基に作成した。撮影においてサンプリング周期は1分間隔とし、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。

実験結果を表2、図7、図8に示す。表2は、在席時の照明制御の精度を示している。ナイーブな制御手法は、在席時、99.9%と間違えて照明を消灯することはないことがわかった。また、本手法でも97.5%とナイーブな制御より少し劣るものの高い精度を示している。本手法の97.5%は3日間で33分間の間違いしか起こさないことから、この差は許容出来るものとする。

また、照明制御の即時性の検証結果は、図7に示す通りである。横軸に2つずつ並べれば棒グラフは、区画単位で見ても在席から離席の状態に移行した離席イベントが起こった事象をサンプリングしてきたものである。9つのサンプルがある。縦軸は、離席イベントが発生してから、照明が消灯制御されるまでの時間を分単位で計測したものである。結果から分かる通り、本手法の方が比較手法よりも早く電気を消すことができていることがわかる。このサンプルでは、ナイーブな手法は最小でも6分程経たないと消灯制御されていない。在席状況の正解データが1分に1度しか収集していないため、カメラの静止画には写っていないが、実際はその区画周辺に居ることが原因と考えられる。動画を用いた方法も考えられるが、1分単位で照明の制御を行なっているため、評価が難しい。また、このグラフからわかるように、ナイーブな手法は在席時電気消さないが、離席

表2 照明制御の精度 (在席時)

提案手法	ナイーブな手法
97.5 %	99.5 %

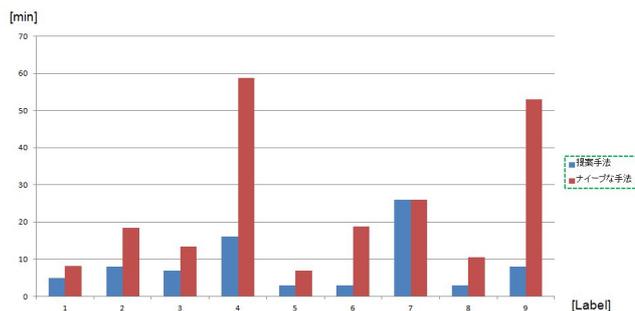


図7 照明制御の即時性

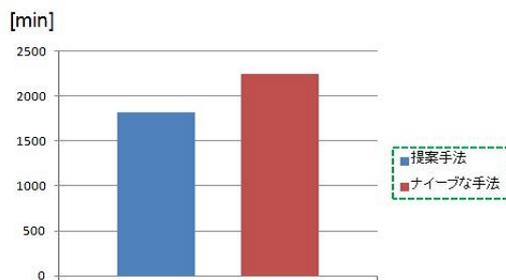


図8 照明機器の使用量

時にも消さないことがわかる。また、他の区画に居る人の動きを検知してしまい、照明が点灯し続けていたと考えられる事象もある。以上、本手法は制御の即時性についても有効に働いていることがわかった。

最後に、照明制御の省エネ効果について検証する。照明制御の省エネ効果の検証には、3日間の照明の点灯時間を比較して検証を行う。結果は、図8に示す。縦軸は分を表し、グラフは3日間の両手法の点灯時間の累計を表す。提案手法の照明の使用量は3日間で30時間半程であるが、比較手法はそれより7時間程多い結果となった。結果として、本手法は比較手法と比較して18.5%の電力の使用の削減効果があることがわかった。

7. 応用：離席イベント推定

本章では、在席推定に基づく照明制御の応用手法となる離席イベント推定による消灯制御について述べる。4.2.2章では、多段階在席推定の1)SingleStream Clustering, 3)MultiStream Classificationの2つの推定結果を用いた消灯制御方法であるStayAway推定による消灯制御手法を提案した。この制御は、照明制御を行う区画に属する3つのセンサノードの短期間の推定結果と長期間の在席推定結果のすべてにおいて離席(Away)の推定がされた時、消灯制御を行う。

また、検知漏れのないように高密度にセンサノードを配置する場合、赤外線センサの検知範囲の形状からどうしても検知範囲の重複が起こりえる。そのため、隣の区画に属する人が区画内に属するセンサノードを反応させるような位置に居たり、動きをすると、消灯制御が行われず、電力消費のムダの生むこと

に繋がる。したがって、在席状態から離席状態に移行する離席イベントを高精度に推定することが出来れば、素早く消灯制御でき、電力消費のムダを抑制することが可能となる。

離席イベント推定は、多段階在席推定の短期間の複数のセンサ群の反応傾向を推定する 2)MultiStream Clustering の結果と、在席状況の正解データを基に分類器学習させ、それを過学習に注意しながら再サンプリングを繰り返すことにより離席イベントを推定する手法である。

まず、過去 1 分間に属する 2)MultiStream Clustering の時系列順の推定結果と、また、在席状況の正解データから得られる各区画の離席イベントの有無を教師データとして用いて分類器学習させる。

しかし、正解データの分布の偏りにより、高精度に推定することができないことがある存在する。実際の環境下における離席イベントは、離席イベントが起こらない場合と比較して、大変少ない。予備実験では、離席イベントでないものが 98% で、各区画の離席イベントの合計が 2% と、大変偏りが存在する。そのため、本手法は、ランダムサンプリングの再サンプリングを行うことで、正解データの偏りの平滑化を行い、精度を上げていく。モデルが過学習にならないように注意しながら、再サンプリングを行う。

過学習とは、機械学習のモデル作成データに依存しすぎることである。モデル作成に使う教師データに依存しすぎてしまうと、モデル作成データでない別のデータに当てはめられた時、精度良く推定することができなくなる。

過学習になりすぎない程度まで再サンプリングを行うことで、高精度な離席イベントを推定することができる。そして、この離席イベント推定を照明機器の消灯制御に利用することで、別の区画の影響を最大限軽減でき、電力消費のムダを抑制することができる。

8. まとめと今後の課題

本論文では、赤外線センサを用いた多段階在席推定手法である $Sc2MC^2$ を用いて、在席推定に基づく照明制御手法を提案した。各センサノードの短期間の反応傾向を推定する 1)SingleStream Clustering の推定結果を利用することで、短期間の行動である移動などを検知することができ、また、センサ群の長期間の在席状況を推定する 3)MultiStream Classification の推定結果を利用することで、長期間の行動である在席を推定することができる。その短期間と長期間の時間スケールの異なる在席推定結果を利用することで、短期間の行動である移動と長期間の行動である在席を分けた制御を行うことができ、ナイーブな一元的な制御と比較して、誤った消灯制御を抑えつつ素早い消灯制御を実現することができる。シミュレーションを用いた実験では、ナイーブな制御手法に比べ、18.5% の省エネ効果があることがわかった。

在席推定に基づく照明制御の今後の課題は、三つが考えられる。一つ目は、シミュレーションを用いない実地の実験である。短期間の実験では、それぞれ別の状況で実験を行うと正確な省エネ効果の検証ができない。長期間の実験を行い、本手法の有

用性を検証する必要がある。また、二つ目は、離席イベント推定を用いた制御の実現と評価である。今回、照明制御手法の応用例として、離席イベントを発見する手法を説明した。実際にシミュレーションや実地の照明制御システムに組み込み、評価検証する必要がある。また、三つ目は、予測などのより高度な照明制御を実現することである。人の行動の習慣性などを抽出し、より利用者の快適性の向上や省エネ化に貢献できる照明制御の実現を行いたい。

本研究の最終目標である省エネシステムの構築としての今後の課題は、在席推定の利活用を進めることである。照明制御だけでなく、空調制御などにも利用範囲を広めることが考えられる。

謝辞 本研究の一部は科学研究費補助金挑戦的萌芽研究(課題番号 22650012)、基盤研究(B)(課題番号 20300027)および地域イノベーション戦略支援プログラム(旧知的クラスター創生事業第 II 期)「自律分散協調ロピキタスネットワーク」の助成による。

文 献

- [1] M Inoue, T Higuma, Y Ito, N Kushiro, H Kubota: "Network architecture for home energy management system", IEEE Transactions on Consumer Electronics, Vol. 49, pp. 606-613,(2003)
- [2] S Kaneko, M Enokizono, T Kamei, E Fujita: "Development of the Drive Dozing Prevention Technique Using a Sensor Installed in the Seat for Detecting the Driver's Condition", ERST2008(2008)
- [3] 大西史花, 渡辺知恵美: "スマートハウスのセンサデータに対する SAX を利用したイベント検出の検討", DEIM2011(2011)
- [4] 小林貴訓: "分散センサの統合によるエリア内人物追跡と動線推定", (2007)
- [5] 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)
- [6] 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)
- [7] UBITEQ: "CFMS by BX-Office", <http://www.ubiteq.co.jp/products/cfmsbybxoffice.html>
- [8] S Honda, K Fukui, K Moriyama, S Kurihara, M Numao: "Extracting Human Behaviors with Infrared Sensor Network", INSS(2007)
- [9] T Hosokawa, M kudo: "Person Trackig with Infrared Sensors", INSS(2005)
- [10] 村尾和哉, 寺田努, 塚本昌彦: "住宅内に設置した人感センサを用いた住人の移動推定", DICOMO2011 シンポジウム (2011)
- [11] D Berndt, J Clifford: "Using dynamic time warping to find patterns in time series", AAAI Workshop on Knowledge Discovery in Databases(1994)
- [12] 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/>
- [13] 江田政聡, 中根傑, 横山昌平, 福田直樹, 峰野博史, 石川博: "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", DEIM2011(2011)
- [14] 株式会社ライトロン: "WebIO", <http://www.lifetron.jp/products.htm>
- [15] X HE, T MIZUNO, H MINENO: "A Study on Office Environmental Control System Using Wireless Sensor Networks", IWIN2011(2011)