

# 照明操作情報とカメラ画像を活用した 学習型在室判定に基づく照明の自動消灯システム

高橋 優香<sup>†1,a)</sup> 五十嵐 正樹<sup>†1</sup> 内山 英昭<sup>†1</sup> 谷口 倫一郎<sup>†1</sup>

**概要:** カメラ画像を用いた学習型在室判定に基づく照明の自動消灯システムを提案する。在室判定の学習のためには、実利用シーンの画像を収集し、在室・不在のラベル付けを行う必要がある。本研究では、日常の照明操作情報に基づき画像の収集及びラベル付けを自動で行うことで、学習を行う際のラベル付けのコストを削減する。また、実環境下における自動消灯システム運用中に在室判定を誤った画像を用いた再学習を行うことで、消灯精度の改善を図る。誤判定画像の収集及び再学習についても自動化し、学習用画像の収集から自動消灯操作、更に再学習による精度改善までを自動で行うシステムを構築する。システムを実環境下において運用した結果を報告する。

## Lighting Control System Based on Trainable Occupancy Detection Using Camera Images and Light Switch Logs

YUKA TAKAHASHI<sup>†1,a)</sup> MASAKI IGARASHI<sup>†1</sup> HIDEAKI UCHIYAMA<sup>†1</sup> RIN-ICHIRO TANIGUCHI<sup>†1</sup>

**Abstract:** We propose a lighting control system based on trainable occupancy detection using camera images and light switch logs. Images used in learning need labeling based on occupancy status in a room. This system automatizes collecting and labeling images by using light switch logs in daily life for reducing labeling costs. Misjudged images during the operation of lighting control system are collected and used in relearning for improving accuracy of lighting control. We constructed our lighting control system and report the results of the system operation in real scene.

### 1. はじめに

エネルギー問題に対する意識の高まりから、様々な省エネルギーに向けた取り組みが行われている。国の施策としては、エネルギーの使用の合理化に関する法律（省エネ法）をはじめとする法制定<sup>1)</sup>や、省エネ技術導入促進のための補助金のサポート<sup>2)</sup>などがある。企業や家庭でも、LEDや低燃費車など省エネルギー性に優れた製品開発および導入が行われている。エネルギーの中でも電力消費量は、生活水準の向上による冷暖房機器等の普及や情報化社会の進展により、1970年から2010年にかけて約3.5倍に増加している<sup>3)</sup>。石油に代表されるエネルギー資源の有限性や化石燃料の燃焼によって発生する二酸化炭素による環境問題

に対する影響が懸念されるなか、省電力対策が求められる。

省電力対策の一つとして、IoT技術を利用したエネルギー管理システム（Energy Management System : EMS）の開発がある。EMSは電力やガス等のエネルギー消費量や温度や湿度等の環境情報や人々の活動状況を各種センサにより計測する。計測されたデータは分析され、削減される無駄なエネルギー消費の把握に役立てられる。EMSの計測および分析結果を元に、エネルギー消費量の可視化や省エネルギーのために推奨される機器利用方法の提示を行う。さらに、ネットワーク経由で制御可能な照明やエアコンなどの電気機器を利用している場合は、センサから得られたエネルギー消費量や環境情報に応じた自動制御まで行う。EMSの中でも管理対象に応じてHEMS（Home Energy Management System）[1]やBEMS（Building Energy Management System）[2]がある。HEMSでは一般住

<sup>†1</sup> 現在、九州大学

Presently with Kyushu University

<sup>a)</sup> yuka\_takahashi@limu.ait.kyushu-u.ac.jp

宅を、BEMS では大型ビルを管理対象としている。いずれの管理対象の場合も、年間の電力消費量全体のうち空調と照明の割合が高く<sup>4)</sup><sup>5)</sup>、自動制御の主な対象となっている。本研究では照明制御による省電力化を行う。

照明の自動制御に用いられるセンサとして、照度センサや赤外線人感センサなどがある。照度センサは、室内の照度を計測し、個人の好みや法令で定められた照度基準を実現するために用いられる [3][4]。この際、太陽光などの外光を取り入れながら照明の調光を行うことによって、必要な照度を維持しつつエネルギーを削減する。人感センサは、空間内の人の有無を判定し不要照明を自動消灯するために用いられる。照明制御の中でも不要照明の自動消灯によって、Anca ら [5] の研究では、オフィス空間において、自動消灯導入前の照明による電力消費量と比較して平均 35 パーセントの削減が見込める。また、Bill ら [6] の研究によれば、会議室から休憩室、トイレなどさまざまなシチュエーションにおいて 16 パーセントから 60 パーセントの削減効果が期待される。不要照明の消灯を効率的に行うためには、空間内の人の有無を素早く正確に判定することが重要である。Anca らや Bill らの手法では、人感センサを用いて在室判定を行う。人感センサは人の動きを検出するため、建物の出入り口や廊下など人の移動が多くみられる空間に用いられてきた。しかし、動きが微小な場合や静止している場合はセンサの検出対象区域内であっても検出が行えない場合があり、誤消灯を行う可能性がある。

本研究では、カメラ画像を用いた学習型在室判定に基づく照明の自動消灯システムを提案する。カメラ画像を用いることで、人感センサで問題となる静止時にも画像情報から在室判定を行うことが可能になる。学習型在室判定を行うためには、実利用シーンに合わせて在室・不在のラベル付けした学習用画像を用意する必要があり、人的コストが大きな問題となる。本研究では日常生活の中での照明操作などの行動をセンシングすることで画像収集時に在室時と不在時のラベル付けを自動で行い、ラベル付けのコストを削減する。また、自動消灯中に在室判定を誤った画像を利用した追加学習あるいは再学習を行うことで、消灯操作の精度向上を図る。誤判定画像の収集及びそれらを利用した学習についても自動化を行い、学習用画像の収集から実環境下での消灯操作、精度改善までを自動で行うシステムを構築する。

## 2. 関連研究

自動消灯のための在室判定の手法として、人感センサで人物の動きを検出する方法や、RFID 技術を用いて個人が所有する RF タグを読み取る方法、着座センサなど家具等にセンサを設置する方法、カメラ画像を用いた方法などがある [7]。以下、それぞれの特徴と利点、欠点について述べる。

熱源である人体の動きに反応して検出を行う赤外線人感センサは、建物の出入り口や廊下、トイレなどの人の移動が多い空間に広く用いられている。しかし、動きがごく微小な場合や静止している場合は、センサの検出範囲内であっても検出が行えない場合がある。そのため、デスクワークを行うオフィス空間などでは、在室中であっても、動きを検出してから次に検出するまでの間隔が大きく空くことがある。誤消灯を防ぐためには、最後に検出を行ってから実際に消灯するまでに待機時間を設定して、一定時間検出がないかを調べる必要がある。待機時間が長くなるほど、誤消灯回数は減少するものの、不在時にも点灯を続けることになるため、省エネ効果を低下させてしまう場合がある [7]。待機時間を短く設定すると誤消灯が増えて利用者の快適性が損なわれ、長く設定すると省エネ効果が損なわれるというトレードオフの関係がある。

利用者の快適性を損なわず効率的な消灯操作を実現するために、Garg らは一日を通じた人々の行動パターンに基づいて待機時間を変更する手法を提案した [8]。具体的には、各人感センサごとに、在室中にどの程度の時間間隔で検出が行われるかを調べる。一日の時間帯ごとに、その時間帯の在室中に検出を行う間隔の大きさを表す統計的なモデルを作成し、人が頻繁に動き、間隔が小さい時間帯の待機時間は短く設定し、デスクワーク中など、間隔が大きい時間帯の待機時間を長く設定する。モデル作成の際、在室中にも関わらず動きがほとんど検出されない時間帯が存在すると、極端に大きな待機時間が設定されるため、人感センサを取り付ける位置が重要になる。キーボードのタイピング動作が検出できるよう、人感センサの視野内に執務者の手元が入る PC のモニター付近やキーボード付近設置する必要があるなど、非常に限定的な位置や範囲の検出に限られる。

RFID 技術を使用する方法では、より高精度な在室判定を行うことが可能である [9]。RFID とは、RF タグのデータを電波によって非接触で読み書きするシステムであり、電波が届く範囲であればタグが遠くにあっても読み取りが可能である。また、これらのシステムでは個人を特定することも可能なため、入室時に各自の好みの照度に合わせた照明を提供するなどの制御を行うことも可能になる。この手法は、オフィスや学校など、入退室を行う人物が特定できる環境であれば、それぞれに RF タグを持たせることで容易に利用可能であるが、公共空間など不特定多数の人が出入りする場所において、全ての人に持たせるのは現実的ではない。

着座センサは座席上の圧力を計測することで執務者の在離席を把握することができ、オフィス環境などにおいて執務スペースの在離席状況を検知するためには有効な手段である [10]。しかし、センサの利用できる空間は、在室時に着席することが想定されている空間に限定される。

カメラセンサでは、画像情報を用いて室内の人物検出を行う。人感センサー同様に汎用的なツールで、不特定多数の人物が入り出す環境においても利用することができる。画像情報を用いて人物検出を行う方法として、現在の画像と予め取得した背景画像間の差分や、連続するフレーム間での差分を用いて検出を行う方法 [11][12] がある。画像間の差分を用いた手法では、照明変動の影響や、Newsham らの研究 [12] によると、パソコンのディスプレイ点灯の誤検出などの問題がある。寺井らは、赤外線カメラを用いて検出対象区域内の過去の温度画像と現在の温度画像の差分を用いた在室検出を行った [13]。オフィスを想定した環境において、着席時および離席時には執務スペースに生じる温度差分が大きく、人が着席している場合には温度がある一定の温度以上のままで大きな温度差分は生まれないことを利用して、静止時にも在室状態の検出を可能にした。しかし、この手法では人の在離席以外に急激な温度変化が生じないことを前提としており、検出範囲内に冷暖房機器の吹き出し口など急激な温度変化が考えられる場所が含まれていたり、新たな熱源となるような電気機器を持ち込んだ場合などは、誤検出する可能性がある。カメラセンサを用いて人検出を行う別の手法として、画像上から人の形状などの人物らしさを捉える特徴量の抽出を行い、識別機を用いて機械学習を行う方法 [14] がある。特徴量の設計によっては人感センサで問題となるような動作のない時間帯においても、画像情報から人物検出を行うことが可能 [15] である。しかし、在室判定のために機械学習を行う際は、実利用シーンごとに在室、不在のラベルが付けられた学習用の画像を用意する必要がある。

本研究ではカメラ画像を用いた学習型在室判定を行う。提案するシステムでは、学習を行う際に問題となる学習用画像のラベル付けのコストを削減するため、画像の収集およびラベル付けを日常生活の照明操作情報を活用することで自動化する。

### 3. 自動消灯システム

本研究で提案するシステムでは、カメラ画像を用いた学習型在室判定を行い、不在判定時に自動消灯を行う。本システムでは、学習を行う際のコストとなる学習用画像の収集およびラベル付けを自動的に行う。さらに、自動消灯システム運用中に判定を誤った画像を用いた追加学習あるいは再学習を行うことで、消灯精度の改善を図る。つまり、学習用画像の収集から、学習結果を用いた自動消灯、誤判定画像を用いた学習による消灯精度向上までを自動化したシステムを構築する。

#### 3.1 初期学習用画像の自動収集

自動消灯を行うにあたり、まず初めの学習に用いる画像を収集する必要がある。以下、初めの学習を初期学習と呼

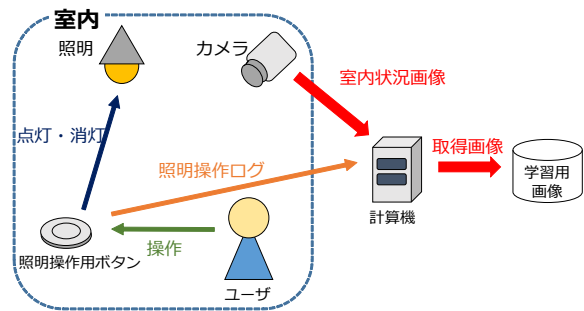


図 1: 初期学習用画像収集時のシステム構成

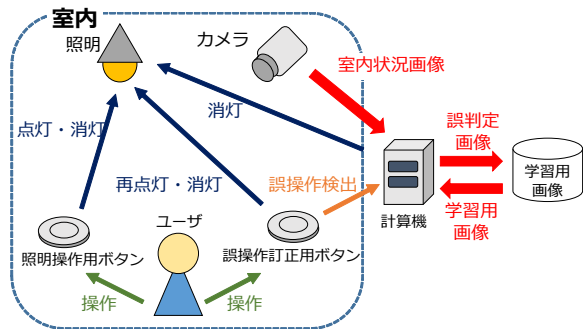


図 2: 自動消灯操作時のシステム構成

ぶ。初期学習用画像は自動消灯を行わない状態の普段の日常生活における照明操作情報を活用して自動的に収集を行う。

初期学習用画像収集時のシステム構成を図 1 に示す。自動消灯のためには照明点灯中の室内の在室判定を行う必要があるため、学習用画像として集める画像は点灯時の在室・不在の 2 通りのラベルが付けられた画像である。ラベル付けを自動で正確に行うためには、画像を取得したタイミングにおける在室状態を推定する必要がある。本システムでは、日常生活における照明操作が操作者の意図を反映しており、操作前後の在室状況を推定することが可能だと仮定できるところに着目して、画像収集を行う。具体的には、点灯操作はその後その空間を利用するという意図があり、在室している可能性が高く、消灯操作後は室内に誰もいない可能性が高いと推定できる。照明操作は、昨今の IoT 技術の普及により、押下情報を取得できるボタンセンサなどを用いて、容易かつ高精度にセンシングを行うことが出来る。本システムでは、日常生活における照明操作をセンシングすることで在室状態を推定し、在室・不在のラベル付けを行う。

照明操作前後の室内の様子と画像取得のタイミングについて図 3 に示す。カメラにより室内状況画像の取得を継続的に行う。在室時画像は、点灯操作が行われた後に取得を始める。室内における様々な位置や状況の画像を取得するために、人が動く度に画像間に差分が生まれることを利用する。カメラにより取得した室内状況画像の画像間差分を取り、変異が見られた場合は在室時画像として取得する。

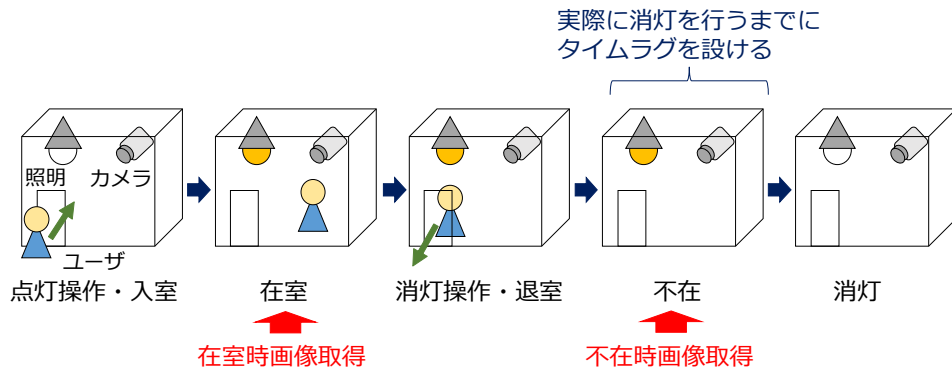


図 3: 照明操作前後の室内の様子と画像取得のタイミング

画像間の差分計算にはゼロ平均正規化相互相関 (Zero-mean Normalized Cross Correlation :ZNCC) を用いる。ZNCC の特徴は、明るさの変動があっても安定的に類似度を計算することができる。

点灯状態の不在時画像は、消灯操作が行われてから実際に消灯を行うまでタイムラグを設けることで取得する。必要な画像は点灯時の不在画像であるため、消灯操作後の室内状況画像間の差分を取り、室内に人がいなくなったことを確認したうえで画像の取得を行う。

### 3.2 自動消灯操作と再学習

初期学習画像収集後の自動消灯操作時のシステム構成を図 2 に示す。在室判定のために特徴量と識別機を組み合わせた機械学習を行う。機械学習を用いた人検出の例として、領域毎の輝度値の勾配から人らしいシルエットを抽出する HOG(Histograms of Oriented Gradients) 特徴量と、学習データをクラス毎に分けるような境界線を計算する識別機である SVM(Support Vector Machine) を組み合わせる方法 [15] がある。また、別の方法として、深層学習を用いる方法 [16] がある。深層学習は、特徴抽出部と識別部から構成され、学習用データから識別に使用する特徴量を自動で抽出する。学習後のモデルを用いて、入力画像が在室時と不在時どちらの状態であるかを判断する。在室判定を一時的に誤った場合を考慮し、一定時間連続で不在と判定した場合に消灯を行う。

本システムでは、自動消灯操作中に判定を誤った際の画像を利用して消灯操作精度の向上を目指す。初期学習用画像の収集期間だけでは、人の服装や椅子の配置等の違いなど、想定されるすべての室内状況の画像を網羅的に集めることは困難である。そのため、初期学習後の自動消灯運用時に実際に在室判定を行う中で、誤る場合も生じる。本システムでは、それらの判定を誤った画像の取得を自動で行い、再学習あるいは追加学習を行ってモデルを更新することで消灯精度の改善を図る。

自動消灯の誤操作を検出するために、誤操作訂正用のボ

タンを室内に設置する。在室中にも関わらず自動消灯した場合には、室内が暗くなるためユーザによる再点灯操作が期待できる。また、不在にも関わらず消灯できなかった場合にも、後々手動での消灯がなされることが期待できる。それらの照明操作を訂正用のボタンにより行ってもらう、訂正用ボタン操作をセンシングすることで、誤操作を検出し、誤判定画像を取得する。また、再学習あるいは追加学習は一定時間ごとに行い、自動消灯に用いるモデルの更新を行う。

## 4. 実験

### 4.1 実験概要

前章で提案したシステムを実装し、実環境下において学習用画像の取得並びに自動消灯操作を行った。また、本実験では誤判定画像を利用したモデル更新を再学習により行った。実験期間中の再学習による消灯操作精度の変化を評価した。

学習には、深層学習の中でも画像認識において有力な手法の一つとして考えられている畳込みニューラルネットワーク (Conventional Neural Network : CNN) を用いた。CNN では、学習用画像から人らしい共通の特徴量を抽出し、識別に用いる。実際の在室判定は、CNN を転移学習させて行った。転移学習とは、事前に目的とは異なる問題用のデータセットで学習済みのモデルを用いて、新たに別の問題に適用するものである。具体的には、一般物体認識のデータセットである ImageNet で学習した AlexNet を用いて転移学習を行った。実際に学習を行ったネットワークを図 4 に示す。ネットワークの出力層では、入力画像が在室時の画像である確率と不在時の画像である確率がそれぞれ出力される。本システムでは、確率が 0.5 を超えた方の状況であると判断し、15 秒連続で不在と判定した場合に消灯を行った。

初期学習用画像の収集期間に集まる画像は、画像間に差分が生じるごとに取得する在室時画像が圧倒的に多くなり、不均衡データ [17][18] になる。そのため、不在時画像




図 4: 学習に用いたネットワーク

の枚数に合わせてアンダーサンプリングを行い、不在時：在室時=1：2になるようにした。これらの画像を用いて学習後、実環境下で消灯操作及び再学習を行った。

本実験で初期学習用の画像の取得を行った期間は 2016 年 12 月 6 日から 12 月 20 日までであり、実環境下で消灯及び再学習を行ったのは 2017 年 1 月 16 日から 1 月 25 日までである。また、再学習は毎時 0 分に開始し、59 分に自動消灯システムに学習後のモデルを更新して自動消灯操作に適用した。

#### 4.2 実験環境

本実験では研究室において、喫茶スペースと呼ばれる共用スペースを利用した。喫茶スペース内における家具や照明の配置を図 5 に示す。喫茶スペースは昼食や冷蔵庫の利用のために頻繁に人の出入りがあり、一日当たりおよそ 30 回程度の点灯操作が行われる。照明操作は出入り口すぐ横の壁に設置されたボタンを用いて行う。在室時にも関わらず、システムが誤って消灯を行ってしまった場合には、机の上に設置されている誤操作訂正用ボタンを押して再点灯を行うことで誤操作を検出する。また、照明と照明操作のボタン、カメラや画像処理用の計算機はすべてネットワークに接続されている。

今回は実験機器として、照明操作並びに誤操作訂正用ボタンには Braveridge 社の BTN01 を利用した。BTN01 は、ボタン毎に、またボタン押下時の一度押し、二度押し、長押し毎に異なる Bluetooth 電波を発信する。本システムでは、照明操作ボタンと誤操作訂正用ボタンに分け、一度押しで点灯操作、二度押しで消灯操作とすることで、センシングする際に照明操作の種類を区別した。また、通信プロトコルとして、MQTT を用いた。MQTT は、IoT の実現に適したプロトコルで、多数のデバイスからのリアルタイム通信に対応するため、IBM 社により考案された。室内状況画像を取得するカメラは MOBOTIX 社の Q24 を利用した。利用したカメラは魚眼カメラであり、喫茶スペースの天井に設置されている。また、得られる画像の周辺は図 6 に示すように室内が写らず黒色であるため、画像取得の際には室内が写っている部分のみを切り出し、さらに 192×192 のサイズに圧縮して学習用画像としている。利用した計算機の性能は表 1 に示す。




図 5: 室内の照明・カメラ・および照明操作機器の設置場所




図 6: 未処理の魚眼画像

表 1: 画像処理に用いた計算機の詳細

項目	スペック
CPU	Intel(R) Core(TM) i7-6800K CPU @ 3.40GHz
OS	Windows 10 Pro
RAM	64.0GB
GPU	NVIDIA GeForce GTX 1080 (8192MB GDDR5X)

#### 4.3 実験結果

##### 4.3.1 初期学習用の画像収集

日常生活における喫茶スペースの照明操作情報をもとに自動で取得した画像数は不在時画像が 100 枚、在室時画像が 12,693 枚であった。実際に取得した画像の例を図 7 に示す。画像中の人の位置を赤枠で示す。

自動で取得した画像のうち、誤ったラベルがつけられていたものは、不在時は 0 枚、在室時は 2 枚であった。誤ってラベル付けが行われた画像の例を図 8 に示す。在室時画像が誤ったラベルで取得された要因として、点灯後に利用者が退出し、照明が点灯したまま不在になっている状態で、喫茶スペース周辺の照明の影響などにより照明変動が起き




図 7: 初期学習用画像として取得した画像の例




図 8: 不在時画像に誤って在室のラベルがつけられた例

たことが考えられる。照明点灯中は画像間に差分が生じる度に画像を取得しているため、照明変動により画像上に変化が生じた場合、不在にもかかわらず在室時画像として取得してしまうことになる。なお、これらの画像は学習の際のアンダーサンプリングで除外されていたために学習には用いられなかった。

#### 4.3.2 再学習および消灯操作精度の評価

初期学習用画像に自動消灯操作中に取得した誤判定画像も含めた学習用画像を用いて、実際に喫茶スペースにおいて自動消灯操作及び誤判定画像を用いた再学習を行った。自動消灯期間内で取得できた再学習用画像は、在室時画像は 19 枚、不在時画像は 30 枚であった。取得できた再学習用画像の例を図 9 に示す。取得した 19 枚の在室時画像のうち、18 枚は一人で在室しているときののものであった。図 9(a) のように、上半身が隠れた状態など、目視でも判別が難しい画像は誤判定することが多かった。

自動消灯操作の精度の評価を行うに当たり、  
 TP=正しく自動消灯を行った回数




図 9: 再学習用画像として取得した画像の例




図 10: 消灯操作の精度の変化




図 11: 随時再学習およびモデル更新を行ったと仮定した場合の消灯操作の精度の変化

FP=誤って自動消灯を行った回数

FN=消灯を行えなかった回数

と置く。この時、TP+FP は実際に自動消灯を行った総回数を、TP+FN は消灯すべきだった総回数を表す。自動消灯を行った総回数と消灯すべきだった総回数それぞれに対

して正しく消灯を行った回数 TP が占める割合をそれぞれ適合率、再現率とする。また、適合率と再現率の調和平均をとった値を F 値とする。計算式を以下に示す。

$$\text{適合率 (\%)} = \frac{TP}{TP + FP} \times 100 \quad (1)$$

$$\text{再現率 (\%)} = \frac{TP}{TP + FN} \times 100 \quad (2)$$

$$\text{F 値 (\%)} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (3)$$

消灯操作の精度の変化の様子を図 10 に示す。

#### 4.4 考察

自動消灯操作の精度は、図 10 に示すように、18 日に大きく下がるなど、日毎にばらつきが存在した。消灯操作の精度に影響を与える要因として、再学習用として取得した画像の種類と再学習を行う時間間隔が考えられる。以下の項でそれら 2 つの要因について述べる。

##### 4.4.1 取得した再学習用画像の種類の影響

判定を誤った画像のうち、96 パーセントは再学習によりその後正しい判定が可能になった。しかし、図 12 に示すように、再学習を行った後も判定を誤る画像が存在した。再学習後も判定を誤った原因として、在室時と不在時で類似した画像が学習用画像の中に含まれていたことが考えられる。在室時画像図 12(a) に類似した不在時画像の例を図 12(c)(d) に示す。在室時と不在時で椅子や机の上の物の配置がほぼ同じ状態で、違いは椅子上のごく一部のみになっている。類似画像の判定結果への影響を評価するために、再学習用に取得した画像から図 12(c)(d) のような類似画像を除いた状態で再学習を行った。学習後のモデルでは、図 12(a) も正しく在室判定することが可能になったために、類似画像は判定を誤る要因になったと考えられる。

##### 4.4.2 再学習とモデル更新を行う時間間隔の影響

自動消灯システム運用中に実際に取得した画像の例と、再学習、モデル更新の流れを図 13 に示す。本実験の学習は概ね 30 分以内で終了するが、学習用画像数の増加に伴う学習時間の増大を想定し、毎時 0 分に学習の開始を、59 分にモデルの更新を定期的に行った。そのため、取得されてから再学習に用いられ、学習結果のモデルが実際の消灯操作に反映されるまでに最大で二時間程度かかる場合があり、その間は同様のシーンを連続して誤ることになる。再学習用に利用した不在時画像には、図 13 に示すように短時間内に連続して取得されたほぼ同様の画像が複数枚含まれていた。

本実験では図 13 において 13 時 43 分に誤判定画像を取得した時点ですぐに学習を行い、モデルを更新して自動消灯操作を行ったと仮定する。14 時の学習によるモデルでは、それ以降の画像を正しく不在判定することができた。同様のケースについて、仮に判定を誤った時点ですぐに学




図 12: 再学習後も判定を誤った画像とその類似画像

習を行い、モデルを更新して消灯操作を行ったと仮定した場合の自動消灯の精度を図 11 に示す。図 10 と比較して、すぐに再学習を行った場合には、連続して同じシーンを誤ることがなくなるため、不在時に消灯を行えない回数が減り、再現率の値が向上する。今回の実験では決まった時間間隔で定期的に再学習およびモデルの更新を行ったが、随時学習及びモデル更新を続けることで、自動消灯精度の向上を図ることができると考える。

## 5. まとめ

本研究では、照明の消費電力量の削減を目指し、カメラ画像を用いた学習型在室判定に基づく照明の自動消灯システムを提案した。学習を行う際に必要となる学習用画像の収集およびラベル付けは、日常生活の照明操作情報を基に自動的におこなった。また、実際の自動消灯操作中に誤った画像の収集及び再学習も自動で行い、自動消灯操作精度の改善を図った。

実環境下において実験を行い、実験期間内における自動消灯精度を評価した。自動消灯システム運用初日と比較して最終日の時点で精度の向上はみられたものの、目視でも在室判定が難しい画像は誤判定しやすいことや、学習用画像の種類や再学習を行う時間間隔が消灯操作の精度に影響を与えることが分かった。今回の実験では決まった時間間隔で再学習やモデルの更新を行ったが、随時学習及びモデルの更新を行うことで消灯操作精度の向上を図ることができると考える。

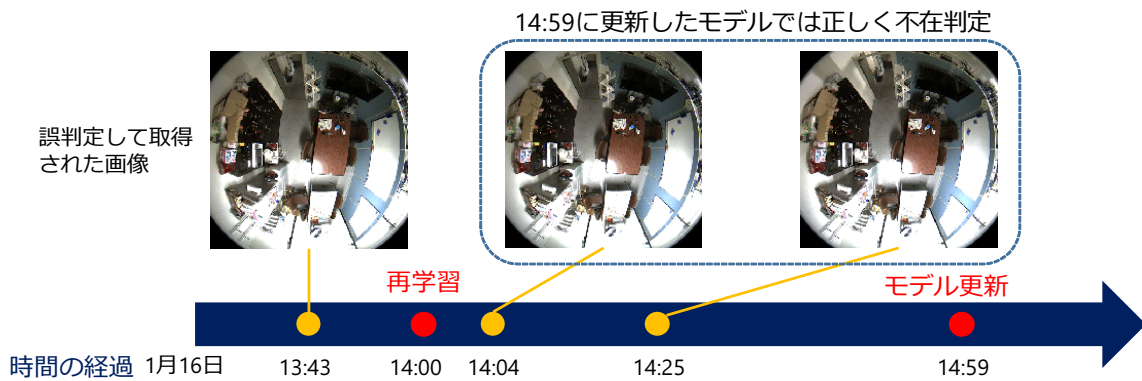


図 13: 再学習用画像を取得してから自動消灯に反映されるまでの流れ

## 注

- 1) 資源エネルギー庁「省エネ法の概要」  
[http://www.enecho.meti.go.jp/category/saving\\_and\\_new/saving/summary/pdf/2014\\_gaiyo.pdf](http://www.enecho.meti.go.jp/category/saving_and_new/saving/summary/pdf/2014_gaiyo.pdf)
- 2) 資源エネルギー庁「国による省エネサポート」  
[http://www.enecho.meti.go.jp/category/saving\\_and\\_new/saving/general/support/](http://www.enecho.meti.go.jp/category/saving_and_new/saving/general/support/)
- 3) 電気事業連合会「日本のエネルギー事情のいま、をお伝えします」  
[http://www.fepec.or.jp/theme/now\\_energy/japan\\_energy\\_01.html](http://www.fepec.or.jp/theme/now_energy/japan_energy_01.html)
- 4) 資源エネルギー庁「トップランナー基準の現状等について」  
[http://www.meti.go.jp/committee/summary/0004310/017\\_s01\\_00.pdf](http://www.meti.go.jp/committee/summary/0004310/017_s01_00.pdf)
- 5) 省エネルギーセンター「オフィスビルのエネルギー消費の特徴」  
[http://www.eccj.or.jp/office\\_bldg/01.html](http://www.eccj.or.jp/office_bldg/01.html)

## 参考文献

- [1] M. Inoue, T. Higuma, Y. Ito, N. Kushiro, and H. Kubota. Network architecture for home energy management system. *IEEE Transactions on Consumer Electronics*, Vol. 49, No. 3, pp. 606–613, 2003.
- [2] K. Iatropoulos, H. Doukas, K. D. Patlitzianas and John Psarras. Intelligent building energy management system using rule sets. *Building and Environment*, Vol. 42, No. 10, pp. 3562 – 3569, 2007.
- [3] E. S. Lee and S. E. Selkowitz. The new york times headquarters daylighting mockup: Monitored performance of the daylighting control system. *Energy and Buildings*, Vol. 38, No. 7, pp. 914–929, 2006.
- [4] S. Matta and S. M. Mahmud. An intelligent light control system for power saving. In *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*, pp. 3316–3321, Nov 2010.
- [5] C. Suvagau, A. D. Galasiu, G. R. Newsham and D. M. Sander. Energy saving lighting control systems for open-plan offices: A field study. *LEUKOS*, Vol. 4, pp. 7–29, 2007.
- [6] D. Manicria, B. V. Neida and A. Tweed. An analysis of the energy and cost savings potential of occupancy sensors for commercial lighting systems. *Journal of the Illuminating Engineering Society*, Vol. 30, No. 2, pp. 111–125, 2001.
- [7] G. P. Henze, X. Guo, D. K. Tiller and C. E. Waters. The performance of occupancy-based lighting control systems: A review. *Lighting Research & Technology*, Vol. 42, p. 415–431, 2010.
- [8] Vishal Garg and N. K. Bansal. Smart occupancy sensors to reduce energy consumption. *Energy and Buildings*, Vol. 32, No. 1, pp. 81–87, 2000.
- [9] N. Li, G. Calis, and B. Becerik-Gerber. Measuring and monitoring occupancy with an rfid based system for demand-driven hvac operations. *Automation in Construction*, Vol. 24, pp. 89–99, 2012.
- [10] T. Bretterklieber, B. George, H. Zangl and G. Brasseur. A combined inductive-capacitive proximity sensor for seat occupancy detection. *IEEE Transactions on Instrumentation and Measurement*, Vol. 59, No. 5, 2010.
- [11] D. M. Gavrilu. The visual analysis of human movement: A survey. *Computer Vision and Image Understanding*, Vol. 73, pp. 82–98, 1999.
- [12] G. R. Newsham and Arsenault. A camera as a sensor for lighting and shading control. *Lighting Research and Technology*, Vol. 41, No. 2, pp. 143–163, 2009.
- [13] 寺井大地, 三木光範, 伊藤克也, 上南遼平, 間博人. マルチエリア型人感センサを用いた在席・離席検知手法の検討. 同志社大学ハリス理化学研究報告, Vol. 56, No. 2, pp. 113–119, 2015.
- [14] 山内悠嗣, 山下隆義, 藤吉弘巨. [サーベイ論文] 統計的学習手法による人検出. 研究報告コンピュータビジョンとイメージメディア, Vol. 2012, No. 18, pp. 1–14, 2012.
- [15] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, Vol. 1, pp. 886–893 vol. 1, June 2005.
- [16] L. Zhao and C. E. Thorpe. Stereo- and neural network-based pedestrian detection. *IEEE Transactions on Intelligent Transportation Systems*, Vol. 1, No. 3, pp. 148–154, Sep 2000.
- [17] H. He and E. A. Garcia. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 21, No. 9, pp. 1263–1284, 2009.
- [18] M. L. Shyu, Y. Yan, M. Chen and S. C. Chen. Deep learning for imbalanced multimedia data classification. *2015 IEEE International Symposium on Multimedia (ISM)*, pp. 483–488, 2015.