

IoT センサーネットワークと実空間における位置情報を用いた 在室状況把握

中村 有佑†

佐藤 周行‡

東京大学工学系研究科†

東京大学情報基盤センター‡

1. はじめに

近年, covid-19 からの経済回復の反動として, 世界各地で電力需給がひっ迫するという事態が発生している [1]. エネルギーは主に住居や学校, ビルをはじめとした建物で消費されている. エネルギー消費の観点から考えると, 建物内の居住状況は重要な要素となる. 例として, 電球の制御や人数に応じた空調設備の制御を行うことによって, 消費エネルギーの低減が実現できる. 居住状況把握システムを作る場合, プライバシーについて配慮する必要があるため, 非侵入型モニタリングシステムが必要となる. 具体的には, 環境センサー (ex. 温度センサー, 湿度センサー, CO2 濃度センサー, 照度センサー) を用いて室内の状況を把握する.

本研究の目的は, 低い計算コストで高速かつ高精度に在室状況の把握を行うことである. 具体的には, 提案手法を用いてパラメータの次元数の圧縮を行い, 計算コストを下げることによって計算速度を上昇させる.

2. 関連研究

Luis らの研究 [2] では, 小さい部屋における在室状況把握について述べられている. 具体的には, 環境センサーデータと機械学習アルゴリズムを用いて, 人がいるかどうかの検出を行った研究である. この研究では, 正解率 Accuracy を評価尺度として用いていた. 改善の余地として, 面積の広い部屋への適用と詳細な人数の把握が挙げられる.

Anisha らの研究 [3] では, スマートメータや Bluetooth 接続可能な環境センサーのデータを用いて, 家電の制御を行い, 10% から 40% の消費エネルギーの削減を実現した. この研究では, 設置コストとランタイムコストを考慮しつつ, 居住者検出を行った. 課題として, IoT ネットワークにおけるセキュリティが挙げられている.

3. 在室状況把握

まず, 実験対象とする室内に IoT ネットワークを構築する. 次に, IoT ネットワークを用いて, 設置した環境センサーから情報を収集する. 室内における位置情報と環境センサーで収集した情報を組み合わせて, データセットを作成する. 最後に, 作成したデータセットに機械学習アルゴリズムを適用して在室人数の推定を行う.

推定後の評価には, MAE, RMSE という評価尺度を用いる. 誤差の大きさを評価する際に, 用いる評価尺度である. MAE は, 平均絶対誤差と呼ばれ, 正解の値と予測した値の差の絶対の総和をデータ数で割ることで求める. 誤差を平均的に評価できる評価尺度である. RMSE は, 二乗平均平方根誤差と呼ばれ, 正解の値と予測した値の差の二乗の総和をデータ数で割った値である MSE の平方根の値を表す. MAE の強みとして, 外れ値の影響を受けにくい点が挙げられる. RMSE の強みとして, 大きい誤差を過大に評価する点が挙げられる. 一方で, 外れ値の影響を受けてしまうという欠点もある. 局所的な誤差も評価に含めた評価尺度である.

4. 実験

実験内容として, 環境センサーのデータを用いて, データセットの作成を行う. そして, 機械学習アルゴリズムを適用して室内における人数の推定を行う. 使用した環境センサーは, 温度・湿度センサーが 10 台, 照度計 1 台, 気圧計 1 台, CO2 センサー 1 台である. 用いるアルゴリズムは, ロジスティック回帰, ガウシアン単純ベイズ, K 近傍法, 決定木, ランダムフォレスト, 勾配ブースティングマシン, サポートベクターマシンである. 対象とする実験室の大きさは 7.2m × 12.8m (W × D) である. データを集めた期間は, 2022 年 11 月 18 日から 2022 年 12 月 12 日である. 実験機材として, Raspberry Pi 4 Model B を用いている. 搭載 GPU は 500MHz (2 コア) である. 表 1 は作成したデータセットの内容を示したものである.

Room occupancy estimation using IoT sensor network and location information

†Yusuke Nakamura, EEIS, Graduate School of Engineering, The University of Tokyo

‡Hiroyuki Sato, Information Technology Center, The University of Tokyo

表 1 データセットの内容

Data Set	Number of observations
Training	10212 of 24 variables
Test 1	4583 of 24 variables
Test 2	5061 of 24 variables

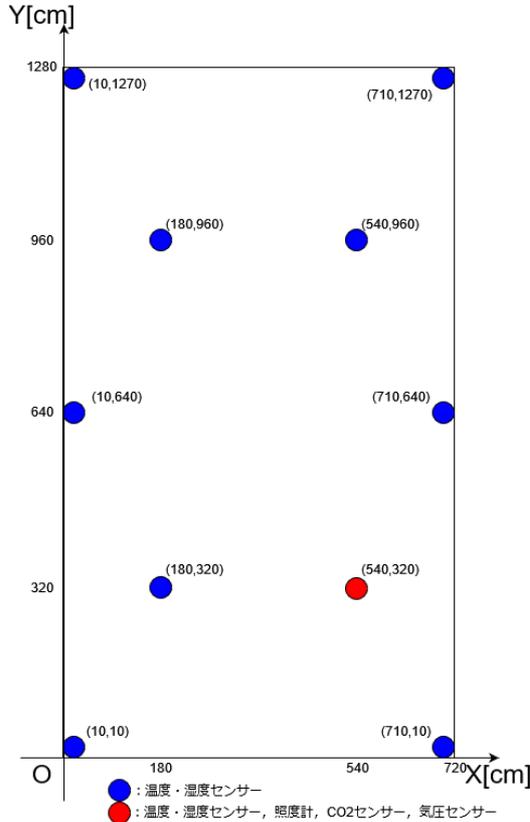


図 1 実験室内でのセンサーの配置座標

図 1 は実験室内に配置した温度・湿度センサーの配置図である。色付きの丸は温度・湿度センサーを表している。

表 2 はロジスティック回帰を用いて訓練データ、テストデータ 2 つに対して推定を行った場合における MAE の数値である。表 3 は表 2 と同じ条件で求めた RMSE の値である。表中の t_{1_1} , t_{1_2} , t_{1_3} , t_2 , t_3 は提案手法を用いて設定した温度である。 t_{1_1} , t_{1_2} , t_{1_3} は伝熱工学におけるフーリエの法則を参考に対象とする座標の温度を求めている。具体的には、距離と反比例して重みづけをして計算している。対象とする座標を t_{1_1} の場合は(360, 640), t_{1_2} の場合は(360, 960), t_{1_3} の場合は(360, 1280)としている。 t_2 , t_3 は伝熱工学におけるラプラスの式と差分法を参考に求めた温度である。具体的には、対象とする座標周囲の 4 つのセンサーが測定した値の平均である。 t_2 の場合は、(180, 960), (540, 960), (180, 320), (540, 320) に設置されたセンサーの値を用いる。 t_3 の場合

は、(10, 1270), (710, 1270), (10, 10), (710, 10) に設置されたセンサーの値を用いる。

表 2 と表 3 より、 t_{1_1} , t_{1_2} , t_{1_3} の手法よりも t_2 , t_3 の方が高い精度を実現できることが確認できた。

表 2 各データにおける MAE の値

Parameter	Training	Test1	Test2
CO2, t_{1_1}	0.529	0.661	0.406
CO2, t_{1_2}	0.523	0.669	0.406
CO2, t_{1_3}	0.515	0.672	0.404
CO2, t_2	0.509	0.561	0.372
CO2, t_3	0.514	0.667	0.412

表 3 各データにおける RMSE の値

Parameter	Training	Test1	Test2
CO2, t_{1_1}	1.041	1.105	0.712
CO2, t_{1_2}	1.034	1.108	0.711
CO2, t_{1_3}	1.021	1.108	0.709
CO2, t_2	1.004	0.958	0.689
CO2, t_3	1.022	1.105	0.716

5. おわりに

提案手法を適用して、環境センサーデータセットを作成し、機械学習アルゴリズムを適用することによって、0.4~1.1 人の範囲の誤差での室内人数把握を行うことができた。これによって、低い計算コストで高速かつ高精度に材質状況の把握を行うという本研究の目的を達成できた。

今後の予定として、スマートメータのデータを用いてデータセットを作成することでより在室状況把握の精度を高め、位置推定に繋げる。また、計算速度を活かして、リアルタイムな検出も実現する。

参考文献

- [1] 経済産業省. 『エネルギー白書』令和三年度版, p. 42
- [2] Luis M. Candanedo, V. Feldheim, "Accurate occupancy detection of an office room from light, temperature, humidity and CO2 measurements using statistical learning models", Energy and Buildings Volume 112, pp.28-39, 2016.
- [3] Anisha Natarajan, V. Krishnasamy, M. Singh, "Occupancy detection and localization strategies for demand modulated appliance control in Internet of Things enabled home energy management system", Renewable and Sustainable Energy Reviews 167, pp.1-24, 2022.