

# 相関型二段階学習に基づく異なる季節データを用いた室温分布推定

角田 啓介<sup>1</sup> 児玉 翠<sup>1</sup> 前島 綜太郎<sup>1</sup> 荒井 直樹<sup>1</sup> 尾花 和昭<sup>1</sup>

概要：本稿では、空調運転最適化による室内環境改善と消費エネルギー量削減を目指し、十数メートル四方からなる広い屋内空間において、ある季節における室温分布データを、異なる季節に長期間、同一季節に短期間計測した学習データを基に推定する方法について述べる。従来、本稿のように推定対象と同一条件下で計測した学習データが少ない場合、異なる条件下において計測した大量のデータを用いて機械学習モデルを作成後、少数の同条件下におけるデータを用いてモデルの一部を再学習する Fine-tuning や、モデルに新たなパラメータを加えた上で追加部分を再学習する転移学習が用いられてきており、これらの手法における学習時の損失は最小二乗誤差や対数尤度といった正解値と推定値の一致度が用いられてきた。しかし、室温分布とそれを推定するために用いる空調システム温度のような、2つの条件下における説明変数と被説明変数の関係が、相関関係が類似していてもその大小関係が一致しない場合、従来手法では高精度な推定が困難であった。

本稿では従来手法の課題を解決するため、異なる条件下における多数データを用いた学習では相関関係を用いることで、相関関係を利用して同一条件下での少量データからの高精度な推定を実現する相関型二段階学習手法を提案する。提案手法を、あるビル内で実測した室温データにおける、異なる季節データを用いて推定に適用することで、その有効性を示す。

## Estimating Multi-points Indoor Temperature from Different Season Data based on Correlation-based Two-Step Learning

Keisuke Tsunoda<sup>1</sup> Midori Kodama<sup>1</sup> Soutaro Maejima<sup>1</sup> Naoki Arai<sup>1</sup> Kazuaki Obana<sup>1</sup>

### 1. 序論

世界的なカーボンニュートラル実現への機運と、日本政府が2050年までに目指すCO<sub>2</sub>排出ゼロに向け様々な省エネ化の取り組みが必要とされている。ここで街中にある大規模な商業施設やオフィスビルに目を向けると、これらのビルは空調や照明等に多くのエネルギーを利用している。特に、空調で消費するエネルギーは全消費エネルギーの40%にも達するという報告 [1] もあり、空調最適化による消費エネルギーの削減と、快適性確保の両立はこれらのビル管理者にとって大きな課題である。

空調制御では一般に、現在の室温と設定された温度を比較したうえで運転を決定するフィードバック制御 [2] が行われることが多い。しかしながら、大規模商業施設やオ

フィスビルにおいては空間が広く、室温の分布にばらつきが生じうるうえ、制御の効果が現れるまで時間がかかるため、1, 2点の室温に基づくフィードバック制御では快適性が損なわれる、あるいは無駄な空調運転を行ってしまうという問題がある。この問題を解決するためには、外気温や混雑といった様々な要素から影響を受ける複数地点の室温分布を把握したうえで、室温分布を最適化する制御が必要となる。しかしながら、広い空間へ複数の温度センサを設置し、長期間データを計測し続けることはコスト増加要因となるため、可能な限り計測コストが低い方法、具体的には計測機器が少なく、計測期間が短い方法が望まれる。

本稿では、空調制御に用いるために必要となる広い空間の室温分布データを、空調システム (Building Energy Management System: BEMS や Heating Ventilation and Air Conditioning: HVAC など) が常時計測している

<sup>1</sup> 日本電信電話株式会社 NTT スマートデータサイエンスセンター

温度データから、同じ季節の学習データが十分でない場合においても、豊富な異なる季節のデータも併用して推定する方法について述べる。近年は、特徴が類似するデータを用いることで少量の学習データを用いた学習と推定を可能とする方法として、Fine-tuning や転移学習が注目されている。これらの手法において、多くの従来研究では最初の学習と2回目の学習で最小二乗誤差や推定カテゴリの不一致を損失として学習していた。しかし、空調のダクト内温度と室温分布のように、2つのデータ間の相関関係がほぼ一定でも、その大小関係が異なる場合、最小二乗誤差をもちいた学習では高精度な推定が困難であった。

本稿では、初回の学習では相関関係を、2回目の学習では最小二乗誤差を損失として用いることで、そのような特徴を持つデータでも Fine-tuning や転移学習による高精度な推定ができる「相関型二段階学習」を提案する。そして、実際にビル内の大空間で測定したデータに適用することで、その有効性を示す。

## 2. 関連研究

### 2.1 室温分布推定

多数の温度計で直接計測せずに室温分布を推定する手法は大きく、熱力学モデルを用いた手法とデータドリブンな手法に分類される。

前者にの代表例としては、数値流体力学 (Computational Fluid Dynamics: CFD) [3] を用いた手法が挙げられる。CFD では一般に、以下のステップで室温を予測する。

- 図面を基に対象空間を定め、計算用の格子 (2次元の場合はピクセル, 3次元の場合はボクセル) を作成する
- 外部との境界面における制約条件となる温度、空気の出入りといった境界条件を設定する
- 計算条件を設定後、運動方程式に基づいたシミュレーションを実行する

CFD では、適切に境界条件を定めれば高精度な室温分布推定が可能である [4]。しかしながら、境界条件には空調や出入口による空気の流入出量や温度、滞在する人数など、非常に多くのパラメータが含まれるため、それらを全て正確に把握し、シミュレーションに導入することは困難である。結果として、実際のビルにおいて高精度な室温分布推定は困難である。

後者の方法としては、機械学習を用いて大量のデータから推定する手法が提案されている。具体例として、Xu らは Deep Neural Network(DNN) の一種である Long Short Term Memory(LSTM) を用いた室温を予測しており [5]、これらを複数地点に適用することで、データを計測し続けることなく室温分布を過去データより高精度に推定・把握できるようになると考えられる。しかし、これらの手法には学習データを計測して用意する必要があるうえ、室温は外気温や空調運転の影響を受けることから、同一季節の

データを学習データとして用意する必要がある。そのため、特に季節による気候変化が激しい場合は、予測対象季節毎に学習データを計測する必要がある。

機械学習ほど大量のデータを必要としない方法としては、カルマンフィルタや自己回帰 (AR: Auto Regression) モデルに基づく推定が挙げられる。一例として、Monterio らは将来室温予測をカルマンフィルタと AR モデルでそれぞれ予測している [6]。しかしながら、これらの手法は DNN と比較すると少量データで動作するものの、モデル内部のパラメータを決定するためデータを用いる関係上、少量のデータや季節の異なるデータが混在しているケースでは内部パラメータをうまく決定できず、高精度な推定のためには結果的に大量のデータが必要となってしまう問題がある。

### 2.2 少量データを用いた機械学習と推定

異なる季節の学習データを室温分布推定に活用できれば、機械学習を用いた推定手法の課題である、同一季節データの収集コストを低減できる。近年は、本課題のような学習データ不足を解決するため、本来学習データに用いるべきデータと類似するデータを用いた転移学習 [7] や Fine-tuning が盛んに研究され、活用されている。

転移学習とは、対象問題とは別のデータで学習したモデルに、少量データで学習したモデルを結合することで、少量データを用いた推定や予測を可能とする方法である。転移学習は主に画像処理 [8] や音声・言語処理 [9] の分野で盛んに用いられているが、室温のような時系列データにおいても、加速度センサや Electroencephalography(EEG) センサデータを用いた行動認識や感情認識へ適用し、認識精度を上げた報告がある [10]。

Fine-tuning とは、学習時に更新されるモデルのパラメータを、あらかじめ他のデータセットで学習したうえで、一部パラメータを少量データで再学習する方法である。Fine-tuning も顔画像からの感情認識 [11] など、画像処理等の分野で盛んに用いられる方法である。

## 3. 要件と課題

### 3.1 要件

本節では本研究の目的と上述の関連研究に基づき、本稿における要件を明らかにする。

まず、広い屋内空間における空調制御を最適化するためには、広い空間を冷やす、または温めるために時間がかかるうえ、大空間内では場所によって室温差が生じる可能性があるため、複数地点の室温を把握する必要がある。

一方で、室温の把握において、もちろん精度が高いことが望ましいが、同時にコストが低いことが望ましい。ここでのコストとは、推定に用いるデータ取得コストと、推定実施時にビルの現場運用者にとっての手間の2つが挙げられる。前者については特に、季節による気候変化が激しい

場合、季節によって室温変化パターンが大きく異なると考えられるが、季節毎に推定用データを取得すると最低でも1年間が必要になってしまう点が問題となり、可能な限り少ない取得データで推定するためには、異なる季節データも活用できることが望ましい。後者については、機械学習を用いた手法では学習データの調整といったチューニングのための試行錯誤などが求められることが多いが、データサイエンスの知識が必ずしも豊富とは限らない現場運用者にとっては、そのような知識やノウハウが必要な作業が可能な限り不要な手法が望ましい。

上記を踏まえると、本稿で求められる室温予測手法の要件は以下となる。

- 要件1 十数メートル四方空間における複数地点の室温分布を精度よく推定できること
- 要件2 季節毎の室温分布データを取得する取得コストを抑えられること
- 要件3 特徴量や学習データの選択といった専門性の高い作業が極力不要であること

### 3.2 課題

本節では上記要件と関連研究に基づき、本稿における課題を明らかにする。

まず、関連研究より、高精度な室温分布の推定には多くのデータが必要であり、かつ季節変化が激しい場合はその季節変化による外気温等の変化に室温が影響を受けるため、季節毎にデータを取得し、パターンを把握する必要がある。しかしながら、そのような1年という長期間のデータ計測は、複数地点のセンサ調達、設置、データの取得と蓄積コストがかかり、ビル管理者としてはできるだけ限られたデータから、室温分布を推定したいというニーズがある。そのため、異なる季節の計測データも併用した、室温分布推定が必要である。

まとめると、本稿での課題は以下ようになる。

長期間の室温分布計測を必要とせず、推定対象と異なる季節の室温分布データを用いて、室温分布を高精度に推定できるか。

## 4. 提案手法

本稿では、空調システムで常時計測している温度を用いた室温分布推定を提案する。その際、長期間の室温分布データ取得を不要とするために、推定対象と異なる季節のデータ、および推定対象と同様だが短期間(1日)のデータからモデルを作成することで、対象季節の室温分布データを推定する手法を提案する、また上記推定を実現するため、空調システム計測温度と室温分布の大小関係は季節によって変化するが、その変化傾向は季節によらず類似していることに着目し、新たに相関関係のみを異なる季節の多数のデータから学習したうえで、少量の同一季節データで再学

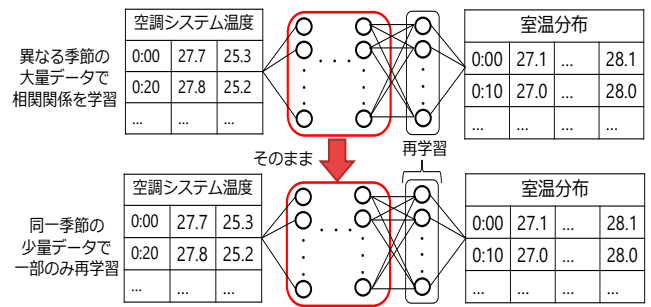


図1 提案手法全体像

Fig. 1 Overall of our proposal

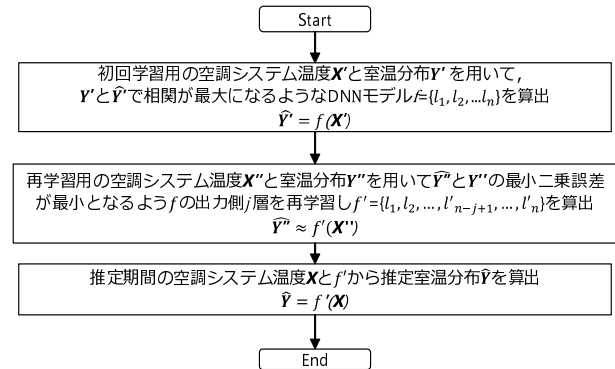


図2 相関型二段階学習手法の流れ

Fig. 2 Flow of our proposal: Correlation-based Two-step learning

習を行う相関型二段階学習手法を提案する。推定手法の全体像を図1に示す。

次に、本手法に用いる学習手法である相関型二段階学習手法について述べる。手法の流れを図2に示す。以下、図2に沿って処理の流れを説明する。

本手法は、初回学習ステップ、再学習ステップ、推定ステップの3ステップからなる。まず初回学習ステップでは、推定対象と異なる季節において計測された、初回学習用の空調システム温度  $X'$ 、室温分布  $Y'$  および以下の式を用いて、 $Y'$  と  $\hat{Y}'$  の相関が最大になるような DNN モデル  $f = \{l_1, l_2, \dots, l_n\}$  を出力する。ここでの  $l_i$  は DNN での  $i$  層目を表す。

$$\hat{Y}' = f(X') \quad (1)$$

再学習ステップでは、推定対象と同一の季節において計測された少量の空調システム温度データ  $X''$ 、室温分布データ  $Y''$  および以下の式を用いて、 $Y''$  と  $\hat{Y}''$  の最小二乗誤差が最小となるよう、初回学習ステップで作成した DNN モデルの出力側  $j$  層を再学習したモデル  $f' = \{l_1, l_2, \dots, l'_{n-j+1}, l'_n\}$  を出力する。

$$\hat{Y}'' = f'(X'') \quad (2)$$

最後の推定ステップでは、再学習ステップで得られた DNN モデル  $f'$  と推定対象期間の空調システム温度データ

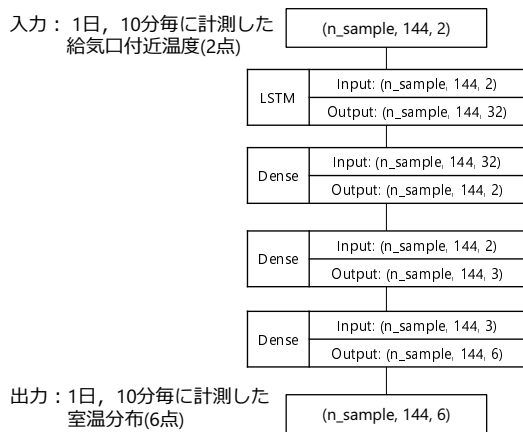


図 3 評価で用いた DNN モデル

Fig. 3 DNN model for evaluation

$\mathbf{X}$  から、室温分布  $\hat{\mathbf{Y}}$  を算出する。

$$\hat{\mathbf{Y}} = f'(\mathbf{X}) \quad (3)$$

## 5. 評価

### 5.1 評価設定

提案手法の有効性を、あるビルのロビーおよび空調システムで実測したデータに基づいて評価した。当該ロビーは幅約 10m, 奥行き約 25m, 高さ約 10m の空間であり、その中の 6 点で室温分布を計測した。また、空調システムは給気口付近で計測している 2 点のデータ (以下、給気口付近温度データ) を用いる、初回学習用データには夏季の 61 日間計測された給気口付近温度データと 6 点の室温分布データを用いた。再学習用データには冬季の 1 日間計測したデータを用い、他の冬季の 41 日間の室温分布データを給気口付近温度データから推定した際の精度を評価した。なお、再学習用データは 5 日分用意し、それぞれのデータで結果に違いが出るか、比較評価を行った。

比較手法として、以下の手法で同様の室温分布データを推定し、結果を比較評価した。

**比較手法 1** 初回学習時に最小二乗誤差を最小化するように学習する以外は、提案手法と同様に学習・推定した結果

**比較手法 2** 再学習用データのみで推定した結果

**比較手法 3** 夏季計測データのみで推定した結果

なお、提案手法、比較手法ではいずれも、LSTM と 3 層の全結合層からなる DNN モデルを用い、再学習の際は 3 層の全結合層のみを再学習させた。図 3 に本稿で用いた DNN モデルを示す。図 3 における  $n_{sample}$  は用いるデータのサンプル数、すなわち日数を表し、長さが 144 なのは 10 分毎のデータが 24 時間分含まれているためである。また、提案手法において、初回学習時の損失  $loss$  は  $loss = 1/(r + 1)$  ( $r$  は推定値と正解値の相関係数) とした。




図 4 各手法での平均推定誤差と誤差の標準偏差

Fig. 4 Average and standard deviation of estimation error in each method




図 5 各手法での推定値と実測値との相関係数

Fig. 5 Correlation coefficient between measured data and data estimated by each method

### 5.2 評価結果

図 4 に各手法での平均推定誤差と誤差の標準偏差を、図 5 に各手法での推定値と実測値との相関係数をそれぞれ示す。なお、比較手法 1, 2 では 5 日の再学習データで 5 通りの推定結果が出力されるため、それらの平均値を示した。

図 6 に提案手法および比較手法 1, 2 の再学習用データ毎の平均推定誤差とその標準偏差を、図 7 に提案手法および比較手法 1, 2 の再学習用データ毎の推定値と実測値の相関係数をそれぞれ示す。

具体的には推定結果として、図 8 にある推定日・地点における各手法の推定値と実測値を示す。

### 5.3 考察

まず図 6 および 7 より、全体として提案手法は全ての比較手法より精度高く室温分布を推定できていることが分かる。また、図 6 および 7 より、特に比較手法 1 では再学習用データ、比較手法 2 では学習用データとしてそれぞれ用いるデータの日付、すなわち特徴によって精度が大きく変わり、平均推定誤差が提案手法よりわずかに小さい場合もありうるが、提案手法では再学習用データの特徴に依存せず、安定して平均誤差 1.0 程度で推定できることがわかる。




図 6 各手法・各再学習用データでの平均推定誤差と誤差の標準偏差  
**Fig. 6** Average and standard deviation of estimation error in each method with each re-learning data




図 7 各手法・各再学習用データでの推定値と実測値との相関係数  
**Fig. 7** Correlation coefficient between measured data and data estimated by each method with each re-learning data




図 8 ある推定日における各手法の推定値と実測値  
**Fig. 8** Measured data and data estimated by each method in a certain target day

よって、提案手法は、要件 1 を満たすといえる。  
 次に、提案手法の精度が高くなった要因を考察する。図 9 に夏季、冬季それぞれにおける室温計測地点 (Point1-6) と給気口付近温度データ (BEMS1, 2) の相関係数を、図 10 に夏季、冬季それぞれにおける室温計測地点 (Point1-6) と給気口付近温度データ (BEMS1, 2) それぞれの温度差の平均値と標準偏差をそれぞれ示す。図 9 より、夏季、冬季共

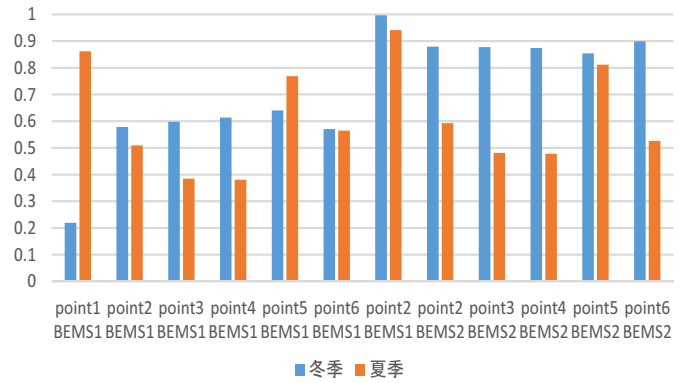


図 9 各季節における室温計測地点 (Point1-6) と給気口付近温度データ (BEMS1, 2) の相関係数  
**Fig. 9** Correlation coefficient between measured indoor temperature data and near duct temperature data in each season

にほとんどの室温計測地点の室温は、給気口付近温度データと正の相関があることがわかる一方、図 10 より、夏季と冬季ではの室温計測地点の室温と給気口付近温度データの差が異なることがわかる。具体的には、冬季は室温の方が給気口付近温度データより低い傾向がある一方、夏季は室温が給気口付近温度データと大きな差がないか、室温の方がやや高い傾向があることが分かる。これは、冬季は空調で温風が出るために給気口付近温度データの方が高い一方、夏季は空調で冷風がでるため、生じる事象であると考えられる。このような、相関関係については季節差が小さいが大小関係が異なる場合において、提案手法は狙い通り、初回学習データで学習した相関関係と、再学習で学習した誤差を反映したモデルを構築することで、異なる季節の豊富なデータがあれば、同一季節の学習データは少数であっても、高精度な推定が可能になったと考えられる。よって、提案手法は要件 2 を満たすといえる。

さらに、再学習用データによる精度差の要因を考察する。図 11 に、再学習データである 5 日の室温分布と給気口付近温度データの平均値を示す。図 11 より、再学習用データにもばらつきがあり、特に day 1, 2 は室温分布と給気口付近温度データの差が、day 3, 4, 5 より大きい傾向が見て取れる。この day 1, 2 の傾向は図 10 で示されているように、推定対象期間における室温分布と給気口付近温度データの関係に類似していると考えられる。そのため、day 1, 2 のデータのみを用いた比較手法 2 による推定では、day 3, 4, 5 のみを用いた同様の推定より精度が高くなったと考えられる。実際、day 3, 4, 5 は室温分布と給気口付近温度データの差が相対的に小さく、図 10 が示すようにむしろ初回学習に用いた夏季の傾向に類似している。このように、学習用データの特徴により、比較手法 2 は精度が大きく変わるが、提案手法ではそのような差異が少なく、いずれの再学習用データを用いても誤差 1.0 度程度で推定できること

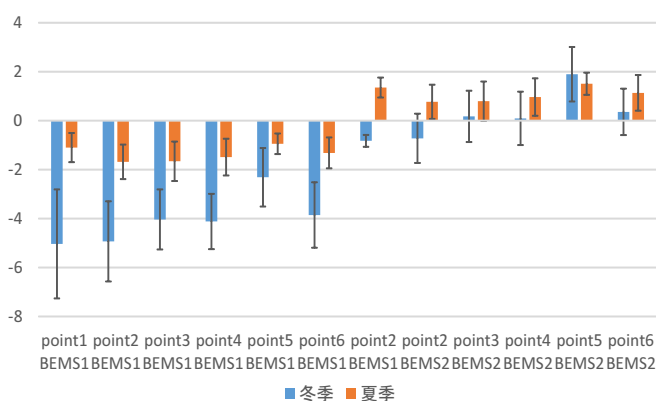


図 10 各季節における室温計測地点 (Point1-6) と給気口付近温度データ (BEMS1, 2) それぞれの温度差の平均値と標準偏差

Fig. 10 Average and standard deviation of differences between measured indoor temperature data and near duct temperature data in each season

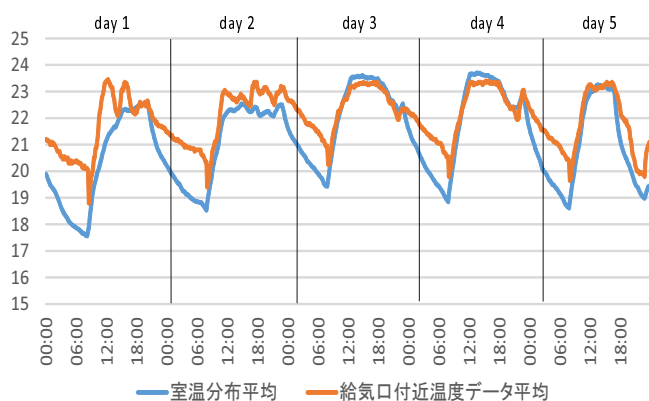


図 11 再学習用データにおける室温分布データ (6 点) の平均と給気口付近温度データ (2 点) の平均

Fig. 11 Average of measured indoor temperature data and near duct temperature data in each re-learning data

がわかり、再学習用データの取捨選択といった専門性の高い作業が不要であり、ビル管理者にとって負荷が低い手法だといえる。よって、提案手法は要件 3 を満たすといえる。

## 6. 結論

本稿では、十数メートル四方からなる屋内空間において、ある季節における室温分布データを、異なる季節に長期間、同一季節に短期間計測した学習データを基に推定する方法を検討した。従来、本稿のように推定対象と同一条件下で学習データが少ない場合、異なる条件下において多く存在するデータを用いて機械学習モデルを作成後、少数の同条件下におけるデータを用いてモデルの一部を再学習する Fine-tuning や、モデルに新たなパラメータを加えた上で再学習する転移学習が用いられてきており、これらの手法における学習時の損失は最小二乗誤差や対数尤度といった正解値と推定値の不一致度が用いられてきた。しかし、

異なる季節における室温分布と空調システム上の温度といった、2つの条件下における説明変数と被説明変数の関係が、相関関係が類似していてもその大小関係が一致しない場合、従来手法では高精度な推定が困難であった。

本稿では従来手法の課題を解決するため、異なる条件下における多数データを用いた学習では相関関係を用いることで、相関関係を利用して高精度な少量データからの推定を実現する相関型二段階学習手法を提案した。そして、実際のビルにおける冬の室温データを、提案手法を用いて豊富な夏の室温データで相関関係を用いて初回学習後、少量の冬のデータで再学習したモデルで推定した。結果、初回学習を誤差最小で学習した比較手法 1 や、少量の同一季節データのみで学習した比較手法 2、異なる季節データのみで学習した比較手法 3 に比べ、初回学習で用いる少量データの特性に依存せず、平均誤差 1.0 度程度の高精度は室温分布推定ができることを明らかにした。

今後の課題として、夏季と冬季を逆にしたケースでの検証や、より広い空間での多点室温分布推定への適用性検証、および同様の特徴を持つデータへの適用検討が挙げられる。

## 参考文献

- [1] 環境省 ZEB Portal 建築物のエネルギー消費状況, <http://www.env.go.jp/earth/zeb/detail/04.html> (最終閲覧日:2021.2.16).
- [2] Brooks, J., Kumar, S., Goyal, S., Subramany, R. and Barooah, P., Energy-efficient control of under-actuated HVAC zones in commercial buildings, *Energy and Buildings*, Vol.93, pp.160-168 (2015).
- [3] Anderson, J. D. and Wendt, J., Computational fluid dynamics An Introduction, New York: McGraw-Hill (1995).
- [4] Nada, S. A., El-Batsh, H. M., Elattar, H. F. and Ali, N. M., CFD investigation of airflow pattern, temperature distribution and thermal comfort of UFAD system for theater buildings applications, *Journal of Building Engineering*, Vol.6, pp.274-300 (2016).
- [5] Chengliang Xu, Huanxin Chen, Jiangyu Wang, Yabin Guo, Yue Yuan, Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method, *Building and Environment*, Vol.148, pp.128-135 (2019).
- [6] Monteiro, P. L., Zanin, M., Menasalvas Ruiz, E., Pimentao, J., and Alexandre da Costa Sousa, P., Indoor temperature prediction in an IoT scenario. *Sensors*, Vol.18, 3610 (2018).
- [7] Weiss, K., Khoshgoftaar, T. M. and Wang, D., A survey of transfer learning. *Journal of Big data*, Vol.3, article No.9 (2016).
- [8] Zhu, Y., Chen, Y., Lu, Z., Pan, S., Xue, G. R., Yu, Y. and Yang, Q., Heterogeneous transfer learning for image classification. *Proc. AAAI 2011*, pp.1304-1309 (2011).
- [9] Wang, D. and Zheng, T. F., Transfer learning for speech and language processing. *Proc. APSIPA 2015*, pp.1225-1237 (2015).
- [10] Li, F., Shirahama, K., Nisar, M. A., Huang, X. and Grzegorzec, M., Deep Transfer Learning for Time Series Data Based on Sensor Modality Classification, *Sensors*,

Vol.20, 4271 (2020).

- [11] Jung, H., Lee, S., Yim, J., Park, S. and Kim, J. Joint fine-tuning in deep neural networks for facial expression recognition. *Proc. IEEE ICCV 2015*, pp. 2983-2991 (2015).