

熱流体シミュレーションを活用した少量データからの室温予測手法の提案

児玉 翠¹ 前島綜太郎¹ 荒井直樹¹ 角田啓介¹ 尾花和昭¹

概要：オフィスビルや商業ビルといった大空間を対象とする空調は、制御してから室温が変化するまでの時間遅れが大きい。この場合、快適さを損なわずに無駄の少ない最適な運転をするためには、フィードバック制御よりも、制御にともなう室温変化を予測し、その予測結果に基づいて制御を行う予測制御が有効だと考えられる。室温予測は、データ量が必要となる機械学習手法と、データ量は必要ないものの測定困難な多数のパラメータが必要な熱流体シミュレーションが存在する。本発表においては、熱流体シミュレーションで用いる測定困難なパラメータを少量データから推定することで、両手法の弱点を克服し、少量データから室温予測をおこなう手法について提案する。

キーワード：温度予測、熱流体シミュレーション、ベイズ最適化

Prediction of Room Temperature using Computer Fluid Dynamics with Small Amount of Sensor Data

1. 諸言

商業ビルの消費エネルギーの約4割が、空調システムにより消費されている[1]。過剰な冷暖房を抑止し、空調を最適に運転することができれば、大幅なエネルギー削減が見込まれる。さらには、施設の管理者にとっては、入居テナントや来場者にとって居心地の良い空間になるような管理・運営が重要である。しかし、日本では少子高齢化や労働力の減少が顕著であり、このような施設の空調管理を含む管理・運營業務にはより一層の効率化が求められている。よって、人手によらず自動的に快適かつ省エネな空調制御を実現するシステムが求められている。

ビルにおける空調においては、多くの施設において計測温度と目標温度の差分に対して制御を変更するフィードバック制御が用いられている[2]。しかし、制御対象となる空間が大規模になるほど、制御を実行してから空調効果が室温に影響するまでの時間は長期化する。このような時間遅れの大きい制御対象においては、フィードバック制御では過剰/過小な空調期間が生じ、快適さが損なわれる上に、過剰にエネルギーが消費されることが予想される。ここで、室温の変化をあらかじめ予測し、予測結果に基づいて制御内容を定める予測制御をおこなえば、時間遅れを克服した、より最適な空調制御が可能になると考えられる。

しかし、商業ビルにおける室温変化の予測は容易ではない。なぜなら、不特定多数の来館者があり、人体の発熱や人の出入りに伴う外気の流入などによって、室内環境が影響をうけるため、人流の考慮が必要である[3]。このような環境では、人の出入りが少ないデータセンタなどに比べて、室内の環境予測がより困難である。

本稿においては、不特定多数の来館者の出入りがある商業ビルにおける空調の予測制御を実現することを目指し、室温や気象、施設内の滞在人数、空調の制御内容といったデータをもとに将来の室温変化を予測する手法について述べる。

従来の室温予測技術では、機械学習手法と流体力学に基づくシミュレーション手法の2種が存在する。機械学習手法は、多量の測定データが必要となること、熱流体シミュレーション手法は測定困難な多数のパラメータにより推定精度が大きく左右されるといった課題がある。本投稿においては、熱流体シミュレーションに用いる多数のパラメータを短期間のデータからベイズ最適化を用いて推定することで、両手法の課題を克服し、短期間の学習データから精度良く室温を再現できる予測手法を提案する。また、提案手法を商業施設における実測データへ適用し、その有効性を示す。

2. 関連研究

温度再現手法として、大きく分けて熱流体シミュレーション手法と機械学習的手法が存在する。

2.1 熱流体シミュレーション手法

熱流体シミュレーションは数値流体力学 (computational fluid dynamics; CFD) を利用して実施されるものであり、対象区間を有限個に分割し生成された計算格子に対し、流体に関する運動方程式を解く数値解析手法である。これを実施するために、以下の手順を踏む。

- 格子の作成

図面をもとに解析対象の空間を定め、特定の間隔で空間を分割し計算格子を作成する。

¹ 日本電信電話株式会社 NTT サービスエボリューション研究所
NTT Service Evolution Laboratories, Minato, Tokyo 108-0023, Japan

- 境界条件の設定
境界面における温度や空気の流入・流出量といったシミュレーションを実行する際の制約条件を定める。
- 計算条件の設定
シミュレーションを実行する時間単位や、シミュレーションのソルバー、各種係数を定める。
- シミュレーションの実行
反復計算により格子ごとの流れ方程式の近似解を得る。計算格子ごとの温度や流速、圧力、密度が算出される。

元来 CFD を利用した熱流体シミュレーションは、建築設計時に行われる場合が主流であるが、近年既存の建物内の室温再現も行われており、飯田らはオフィスビルにおいて詳細な境界条件設定および、空調システムの試ミューレータと連成解析をおこなうことで、平均二乗誤差が 1 度以下という高精度な再現に成功している[4]。

近年、シミュレーションにおける予測誤差を少量の観測データで補正する、「データ同化」の検討も特に気象シミュレーションの分野で発展している[5]。室内環境に対する熱流体シミュレーションにおいても、データ同化の検討はなされており、観測値と予測値の誤差を最小化するシミュレーションの補正項を推定することで予測を高精度化する VCA 法[6]を用いた室内環境の推定がおこなわれている。

しかし、不特定多数の人の出入りなどを考慮した複雑な環境下での予測は、元来境界条件の設定がそもそも不可能であることからおこなわれていない。

2.2 機械学習手法

室内温度を DNN 等の機械学習的な手法を用いて予測する検討がおこなわれている[7, 8]。しかしながら、先行研究では、出入りする人の影響は考慮されておらず、商業施設への適用は難しい。また、空調制御へ室温予測を活用することを見据えると、季節変動を考慮しながら空調制御の影響を学習する必要がある。しかし、機械学習の手法にて空調制御の影響を学習するには多様な空調制御パターンを実行した際の計測データを長期間取得しなければならない。このような計測のハードルのある問題であるため、本検討の目的に合致する検討例は見られなかった。

3. 要件と課題

3.1 要件

本節では、本稿で目指すべき室温予測の要件について述べる。まず、本稿での支援対象は前述のように、商業ビルや駅をはじめとする、不特定多数の人間が常時行き交う空間である施設の管理や運営である。よって、室温変化を予測するにあたっては、人流の影響を考慮する必要がある。

次に、空調制御への活用を見据えると、様々なパタンの空調動作の影響を考慮する必要がある。

また、空調制御は室温に影響を与えるため、室温予測に基づく空調制御を行う場合、直近の制御の影響を考慮して制御を決める必要がある。これを実現するには、時刻 $t-1$ までの制御や環境データを入力として時刻 t の室温を予測し、次に時刻 t までの制御および環境データ(前時刻予測時に予測された室温データを含む)を入力として時刻 $t+1$ をおこない、単位時刻ごとに予測を繰り返す必要がある。

運用面を考慮すると、空調は季節変動の影響を多分に受けるため、季節ごとにモデルが必要になることが想定されるが、長期間の学習データが必要となると、導入初年度におけるシステムの稼働期間が短くなる。センサーを導入してからすぐにシステムを稼働させるためには、短期間の学習データによって室温を予測できることが望ましい。

また、単位時刻ごとに空調制御を切り替える運転を想定すると、1 日の制御パターンは膨大な数が想定される。適切な空調制御を探索するためには、1 度のシミュレーションにかかる時間を可能な限り短くする必要がある。

本稿における室温予測の要件は、以下のようになる。

- 人流のような動的な条件を反映した室温予測ができること
- 過去に実施していない空調の運転パターンを考慮した予測ができること
- 単位時刻ごとに決定される空調制御を反映した予測をおこない、予測された結果を次時刻の予測の入力値とすること
- 学習に利用するデータ期間が数日~1 週間程度であること
- 1 ステップの室温予測の計算時間が 0.5 秒以内であること

3.2 課題

上記の要件と関連技術より、本稿で解くべき課題を明確化する。

まず、上記要件を全て満たす既存技術は現時点では存在しない。機械学習的アプローチでは、長期の学習データが必要とする上、多様な制御パタンの影響を考慮したモデルを作成しようとする、多様な制御パタンの実測データが必要になる。例えば、利用者が少ない時間帯やエリアに対して、空調を弱める、もしくは数時間後の温度変化を見据えてあらかじめ冷やしておく、といった制御を行う可能性があるとする。しかし、営業中の施設においては、そのような制御はクレームが生じるリスクが高く、人手による運用ではなされていない可能性が高い。また、学習データ取得の為に大量の多様な制御パタンの実行を行うことは現実的ではない。よって、機械学習的アプローチに必要な学習データを取得することは困難である。

一方で、熱流体シミュレーション手法では、流体力学に基づいて予測されるため、過去に存在しない制御パターンでもある程度制御の影響を加味した温度予測が行われることが推測される。また、長期の学習データも必要としない。この手法の課題は、多数の境界に対して、温度や風量等の条件を定める必要があり、特に人の出入りを考慮した複雑なモデルでその境界条件を随時計測することは困難であることである。つまり、この境界条件設定さえ適切に設定できれば、長期の学習データなしに多数の制御パターンを考慮した室温予測が可能になると考えられる。

以上により、本稿における課題は以下のようなになる。熱流体シミュレーションにおいて、設定困難な境界条件を計測可能なデータから推定することで、精度良く室温予測をすることが可能か。

4. 提案

4.1 境界条件の推定方法

本稿では、少量の学習データで多様な制御パターンを再現しうる室温予測を実現するために、熱流体シミュレーションに必要とされる境界条件を実測データから推定することを提案する。図 1 に測定データと境界条件の関係を示す。

ここで、ある境界条件を y_i 、測定データを x_j としたときに、式 1 の関係で表すことができる。 w_{ij} は j 番目の測定データの i 番目の境界条件への重みであり、 b_i は i 番目の境界条件へのバイアス項である。 w_{ij} および b_i は初期値としてはランダムな値を代入する。

$$y_i = \sum_j^J w_{ij}x_j + b_i \quad (1)$$

次に、式 1 により決定された境界条件を用いて、シミュレーションを実行し、予測室温と実測温度の誤差を算出する。このとき、ある格子点 k の予測値が $pred_k$ 、実測値が obs_k であった場合、予測誤差 L を式 2 のように定義することができる。

$$L = \frac{1}{n} \sum_{k=1}^n (pred_k - obs_k)^2 \quad (2)$$

最後に、 w_{ij} および b_i を更新しながら、予測誤差を最小化するパラメータを求める。最適化には様々な手法が存在するが、本稿においては、 w_{ij} および b_i の変更にもなる予測誤差の変化が不明であること、シミュレーションコストが大きいことから、ベイズ最適化[9]を用いることとする。

なお、以降 w_{ij} および b_i を「境界条件パラメータ」と記載することとする。

4.2 システム全体像

本稿における提案手法を含めたシステムの全体像を図 2

に示す。本システムは、環境データ取得部、シミュレーションモデル作成部、境界条件推定部、シミュレーション実行部の4つから成り立つ。また、本提案技術である、境界条件推定部の動作フローを図 3 に示す。まず初めに、環境データ取得部において、建物内の人流データおよび温湿度データ、気象データ、BEMS(Building and Energy Management System)データといった実測データを取得し、本システムに入力する。次に、シミュレーションモデル作成部において、建物の図面情報をもとにあらかじめ本シミュレーションを実行する対象空間を定め、出入り口や空調の吹出し口といった境界部を定める。次に境界条件設定部において、実測データと境界パラメータの初期値を用いて境界条件を算出する。算出された境界条件をシミュレーションモデルに設定し、シミュレーション実行部にて次時刻における環境変化を予測する。室温の予測値と実測値を誤差評価部において前項の式 2 に基づいて評価し、予測誤差を得る。算出された誤差に基づいて、境界条件パラメータを更新する。

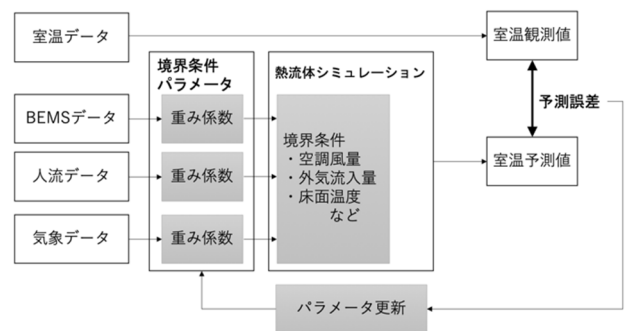


図 1 境界条件と実測データの関係

Figure 1 Relationship between boundary conditions and sensor data

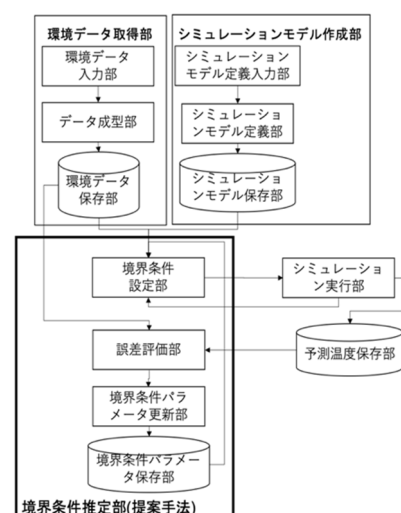


図 2 システム全体像

Figure 2 Proposal system

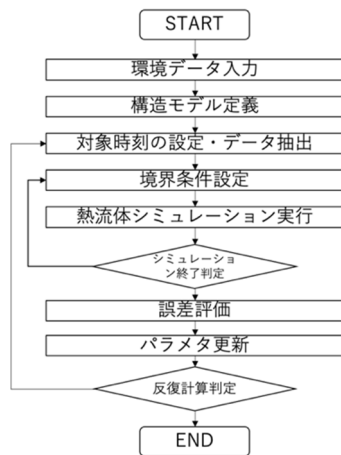


図 3 境界条件パラメータ推定型熱流体シミュレーションの処理フロー

Figure 3 Processing Flow of room temperature prediction by computer fluid dynamics with estimated boundary condition

5. 実データを用いた評価

5.1 センサーデータの取得

本手法を評価するため、実際の不特定多数の人の出入りがある営業中の施設において、人流および温湿度を測定した。人流軌跡データは、本検討の対象領域内に設置された LRF センサおよび LRF システム[10]を用いて取得された。得られた人流軌跡データから、対象領域内の複数のエリアにおける 10 分ごとの滞在人数をカウントした。温湿度センサも LRF センサと同様の場所へ配置し、床面から 1m 程度の高さにおける温湿度を 10 分ごとに記録した。なお、この温度センサシステム[11]における測定誤差は 0.5°C 程度である。

気象データとしては、気象予報サービス[12]を用いて施設の所在地の 1km メッシュ区間の当日の実測の外気温度を取得した。さらに、空調動作に関連する BEMS データを取得した。BEMS データに含まれる空調機の給気温度および室内の設定温度およびダクト内の計測温度を 10 分間隔のデータとして取得した。

5.2 シミュレーションモデル

熱流体シミュレーションの計算には、OpenFOAM[13]を用いて実行した。OpenFOAM は、C++で開発された有限体積法を中心とする偏微分方程式ソルバーの OSS ライブラリである。C++に準じた初期条件ファイルを構成することで、シミュレーションモデルの作成からシミュレーションの演算を実行することができる。

まず、シミュレーションモデルの構造について説明する。本稿においては、1 ステップ(10 分後)の予測を 1 秒以内で処理したいため、計算格子は一辺 1m の立方体とした。建物構造の図面を元に対象空間を定め、対象空間を計算格子

に分割すると、計算格子の数は約 8500 であった。また、本検討において、考慮した境界は表 1 の通りである。シミュレーションは表 2 の条件下で実行した。

5.3 境界条件の推定

境界条件と計測データの関係は、式 1 のように表せるが、実データを用いた評価では影響を与えうる要素を予め想定することが可能であるため、式 3-5 のように定義した。

$$v_{a,i} = w_a(ot_i - st_i) \quad (3)$$

$$v_{o,i} = w_o p_i \quad (4)$$

$$t_{f,i} = w_f p_i \quad (5)$$

式 3 は、空調吹き出し口の流入風量と計測値の関係を表す。 $v_{a,i}$ は、 i 番目の空調吹き出し口から室内への流入風量を表す。 ot_i は i 番目の空調吹き出し口の空調システムの動作の対象となるダクト内温度、 st_i は i 番目の空調吹き出し口の空調システムにおける目標設定温度である。ここで、 w_a は i にかかわらず共通の重みパラメータである。

表 1 対象空間に含まれる境界条件

Table 1 Boundary conditions included in the target space

	個数	境界種類	設定温度	空気の流入/流出
空調吹き出し口	25	パッチ	給気温度	提案手法により推定
外気流入口	2	パッチ	外気温度	提案手法により推定
排気口	5	パッチ	室温の平均温度	自然流入 (境界面の気圧を大気圧として設定)
床面	4	壁	加熱量を提案手法により推定	-
壁面・天井	5	壁	室温の平均温度	-

表 2 CFD 解析条件

Table 2 Analysis conditions of CFD

解析方法	Buoyant Boussinesq PIMPLE 法 (非圧縮性非定常流れを仮定し、ブシネスク近似による浮力を考慮)
乱流モデル	RAS, k- ω モデル
初期室温	早朝の計測値から 3 次元補完したもの
計算周期	10 分

式4は、外気流入口からの流入風量と計測値の関係を表す。 $v_{o,i}$ は、 i 番目の外気流入口からの流入風量を表し、 p_i は i 番目の外気流入口に対応するエリアの人流量を表す。 w_o は i にかかわらず共通の重みパラメータである。

式5は、床面からの加熱量と計測値の関係を表す。本来、床面は床暖房や日光により温められることがなければ、室内の空気を加熱しないが、本手法においては人や照明、機器からの発熱を簡略化して床からの発熱として取り扱う。 $t_{f,i}$ は、 i 番目のエリアにおける床面の加熱量を表し、 p_i は i 番目の外気流入口に対応するエリアの人流量を表す。 w_f は i にかかわらず共通の重みパラメータである。

式3-5に表される重みパラメータを最適化するため、式2で示される予測誤差を用いた。重みパラメータの更新は、1日の予測が終了した際とし、式2の予測誤差を空調運転時間中である8:00-20:00の時刻において加算したものを最適化の目的関数とした。最適化の計算にはpythonのベイズ最適化のライブラリである、GPyOpt[14]を用いた。

5.4 評価方法

評価においては、以下の3つの手法を比較した。

- (比較手法) 設計上想定される境界条件を使用する
- (提案手法1) 初日の3日間のデータを用いて、境界条件重みパラメータを推定する
- (提案手法2) 最初の10日間のうち、外気温変動の傾向が異なる3日間を選定し、選定された3日間を学習データとして境界条件重みパラメータを推定する

本稿においては、2019年9月1日~30日の1ヶ月分のデータを用いた。学習データは、提案手法1の場合9月1~3日を、提案手法2の場合は、9月1, 3, 8日を用いた。評価データとしては、すべての手法において学習データに使用されていない、9日~30日のデータを用いた。

評価指標として、空調の運転中の時刻である、8:00~20:00を対象とし、予測値と実測値の一日の平均絶対誤差を用いた。

日毎に算出された平均絶対誤差に対して、多元配置分散分析により(1)手法、(2)測定点、(3)予測日の3要因の主効果およびそれらの交互作用があるかを検討した。また、主効果および交互作用がある場合に、事後検定としてTukey-Kramer法による多重比較検定をおこなった。

5.5 評価結果

平均絶対誤差に対する、手法、測定点、予測日についての主効果および交互作用を表3に示す。各手法における、全測定点・全時点の予測誤差について、平均絶対誤差、二乗平均平方根誤差、および標準偏差を表4に示す。表3において、手法の主効果が認められることから、事後検定としてTukey-Kramer法による多重比較検定をおこない、提案手法1および提案手法2共に比較手法に比べて平均絶対誤

差が有意に小さいこと、提案手法2の方が提案手法1よりも平均絶対誤差が有意に小さいことが示された。

各手法における各測定点の平均絶対誤差を図4に示す。表3において測定点の主効果および手法と測定点の交互作用が認められたことから、事後検定として測定点ごとの手法間の平均絶対誤差についてTukey-Kramer法による多重比較検定を実施し半分以上の測定点で有意差が認められた。

各手法における各予測日の平均絶対誤差を図5に示す。表3において予測日についての主効果および手法と予測日の交互作用が認められることから、事後検定として予測日ごとに手法間の平均絶対誤差の差をTukey-Kramer法による多重比較検定により検証し、半分以上の予測日において有意差が認められた。

最後に、提案手法2における室温予測の例として、最高気温が高く、外気温変動が大きい2019年9月11日と、最高気温が低く、外気温変動が小さい2019年9月20日の予測例を図6図7に示す。室温変化のトレンドに追従して室温予測ができていたことが確認できた。

表3 平均絶対誤差に関する多元配置分散分析

Table 3 Results of factorial ANOVA

	平方和	自由度	F 値	p 値
手法	72.1	1	366	**
測定点	30.9	9	17.4	**
予測日	96.6	21	23.4	**
手法 × 測定点	35.0	9	19.8	**
手法 × 予測日	47.7	21	11.5	**
測定点 × 予測日	33.3	189	0.89	n.s.

** : $p < 0.01$

表4 全測定点・全時点に対する予測誤差

Table 4 Prediction error of room temperature in all time point

	平均絶対誤差 (MAE)	二乗平均平方根誤差 (RMSE)	標準偏差 (STD)	比較手法との差	提案手法との差
比較手法	1.48	1.75	0.94	-	-
提案手法1	1.11	1.29	0.66	**	-
提案手法2	0.67	0.78	0.39	**	**

** : $p < 0.01$




図 4 各手法における各測定点の平均絶対誤差

Figure 4 Mean Absolute Error of Each Measurement Point in Each Method




図 5 各手法における各予測日の平均絶対誤差

Figure 5 Mean Absolute Error for Each Prediction Date in Each Method




図 6 最高気温の高い日の予測例

Figure 6 Prediction example of a day with a high maximum temperature




図 7 最高気温の低い日の予測例

Figure 7 Prediction example of a day with a low maximum temperature

6. 考察

6.1 手法間の比較

表 3 および表 4 より、2つの提案手法の方が比較手法より平均絶対誤差の少ない予測が可能であり、特に提案手法2のほうが提案手法1に比べて有意に平均絶対誤差が少ない予測が可能であることが示された。提案手法2においては、全測定点、全予測日の平均絶対誤差が 0.67°C で予測されたが、温湿度センサの計測誤差が 0.5°C であることを踏まえると、十分な精度であると考えられる。

次にその要因について考察する。比較手法においては、設計時の空調機器の能力や、人の発熱を人数から考慮して境界条件として定めた。しかしながら、多くの日においては予測値が実測値を大きく下回る例が散見された。設計時の空調能力はあくまでも想定であり、実際には経年劣化や、施設的环境次第で空調の効果が想定通りに発揮されない場合がある。また、外気の流入に関しては出入り口の風量を測定できないために考慮できていない。このような想定される環境と実際の環境差があることにより、比較手法における誤差が拡大したと考えられる。

一方、提案手法においては実際の予測温度に対して空調の効きや外気流入の程度については、重みパラメータとして表現しているため、実際の環境により近い空調能力や外気流入を考慮した環境を再現できたのだと考えられる。

6.2 測定点ごとの予測誤差

表 3 の示す通り、測定点の主効果および、手法と測定点の交互作用があり、手法と測定点によって平均絶対誤差に有意な差があることが示された。図 4 に記載される Tukey-Kramer 法による多重比較検定の結果から、測定点 a, b, c, d, e, i, j においては比較手法よりも提案手法の誤差が有意に少ないことが示された。比較手法と提案手法の差が見られた測定点は特に人通りが多い場所、外気流入口に近い場所

であった。一方、比較手法と提案手法の誤差に有意差がない測定点は、部屋の奥の人通りが少ない場所であった。比較手法は、人流の大小や外気流入量を考慮できていないため、人流や外気流入の影響を受けやすい測定点で誤差が大きくなったと考えられる。一方、提案手法は、重みパラメータにおいて人流や外気流入の効果を表しているため、誤差が少なくなったと考えられる。

6.3 予測対象日ごとの予測誤差

表 3 の示す通り、予測日の主効果および、手法と予測日の交互作用があり、手法と予測日によって平均絶対誤差に有意な差があることが示された。図 5 に記載される Tukey-Kramer 法による多重比較検定の結果から、一部の予測日には比較手法と提案手法において予測誤差に有意な差が認められ、一部の予測日には差は認められなかった。また、提案手法 2 と提案手法 1 を比較すると提案手法 2 の方が比較手法と比べて有意に誤差が少ない日が多かった。提案手法 1 は 9 月の初日 3 日間から学習し、提案手法 2 は 9 月の最初の 10 日間のうち、外気温変動が異なる 3 日間を抽出して学習させている。すなわち、提案手法 1 は似通った環境に合わせた過学習が起きていることが推測され、一方提案手法 2 では、提案手法 1 に比べて異なる外気温トレンドに対応した汎用的な温度再現が実現されていると考えられる。

7. 結言

本稿では、不特定多数の人間が集まる施設の空調を最適に制御することを目指し、少量のデータから人流を考慮した温度予測を行う手法を提案した。本稿の貢献は以下のとおりである。

- 不特定多数の人間の集まる施設の空調制御を見据えた温度予測の要件として、人流の影響を考慮する必要がある点、過去に実施していない空調制御パターンを考慮する必要がある点、学習に利用するデータ期間が短くても予測ができる必要がある点を明確化した。
- 上記要件から、熱流体シミュレーションの設定困難な境界条件を推定することで、人流を考慮した複雑な環境下の室温予測手法を提案した。
- 提案手法を実際の施設で計測したデータへ適用した結果、3 日間の学習データから比較手法と比べて高精度に温度予測が可能であることを確認した。提案手法のように、境界条件を定める重みパラメータを推定することで、現状では測定困難な環境を模擬的に表現することが有効であることが確かめられた。
- 外気温の特性が異なる日を選定した学習データを用いた場合には、より汎用的に予測がなされ、平均絶対誤差 0.67°C で予測できることが確認された。本シ

ステムを運用しながらデータを蓄積するうちに、多様な学習データによって次第に精度が向上される可能性が示された。

今後の課題として、学習データの抽出方法の高度化や、シミュレーションモデル作成と境界条件推定の自動化および他施設への汎用化が挙げられる。

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] 松葉匡彦, et al. "F-51 空調 PID 制御:(その 1) 効率化のための制約条件." 空気調和・衛生工学会大会 学術講演論文集 平成 10 年. 公益社団法人 空気調和・衛生工学会, 1998.
- [3] 進藤宏行, et al. "屋外への開放部を持つ空間における人流・気流センサを用いた空調制御手法の開発・実証 (第 1 報) 開発・実証システムの概要と実証 1 年目の結果." 空気調和・衛生工学会大会 学術講演論文集 令和元年度大会 (札幌) 学術講演論文集 第 9 巻 エネルギー管理 編. 公益社団法人 空気調和・衛生工学会, 2019.
- [4] 飯田玲香, 富安雄太, 白石靖幸. "オフィスビルにおける自然換気併用空調システムの性能検証: 第 2 報-建築物総合 ES ツールと非定常 CFD の連成解析による検討." 空気調和・衛生工学会 論文集 40.216 (2015): 27-35.
- [5] 三好建正, 本田有機. "気象学におけるデータ同化." 天気 54.4 (2007): 287-290.
- [6] 松尾智仁, et al. "連続的データ同化法 (VCA 法) を用いた室内環境推定手法の開発 (第 4 報) 制約条件の追加による放出源推定の精度向上." 空気調和・衛生工学会大会 学術講演論文集 平成 27 年度大会 (大阪) 学術講演論文集 第 5 巻 熱負荷・外皮性能・シミュレーション 編. 公益社団法人 空気調和・衛生工学会, 2015.
- [7] Lu, Tao, and Martti Viljanen. "Prediction of indoor temperature and relative humidity using neural network models: model comparison." *Neural Computing and Applications* 18.4 (2009): 345-357.
- [8] Xu, Chengliang, et al. "Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method." *Building and Environment* 148 (2019): 128-135.
- [9] Javier González, Joseph Longworth, David James, Neil Lawrence. "Bayesian Optimization for synthetic gene design." *The Neural Information Processing Systems (NIPS'14) Workshop in Bayesian Optimization* (2014).
- [10] 日立情報通信エンジニアリング 動線計測ソリューション, <https://www.hitachi-ite.co.jp/products/o-tracking/index.html> (最終閲覧日:2021.2.16).
- [11] 株式会社テストー 無線温湿度データロガー https://www.testo.com/ja-JP/data-logger-and-monitoring/wifi-data-logger/c/product_type_data_logger_monitoring_wifi_data-logger (最終閲覧日:2021.2.16).
- [12] 越智正昭. "気象ビッグデータの活用で社会を元気に!~ 株式会社ハレックスの取組み~." 映像情報メディア学会誌 70.5 (2016): 488-493.
- [13] Jasak, Hrvoje, Aleksandar Jemcov, and Zeljko Tukovic. "OpenFOAM: A C++ library for complex physics simulations." *International workshop on coupled methods in numerical dynamics*. Vol. 1000. IUC Dubrovnik Croatia, 2007.
- [14] Gonzalez, Andrei Paleyes and Javier GPyOpt, <https://sheffieldml.github.io/GPyOpt/> (最終閲覧日:2021.2.16).