

## 少量パターンデータ学習と特徴量寄与度を考慮した予測モデル選択に基づく非定常室温予測 Prediction of Unsteady Indoor Temperature with Small Data Learning and Prediction Model Choice Based on Feature Contribution

前島綜太郎<sup>†</sup> 角田啓介<sup>†</sup> 児玉翠<sup>†</sup> 荒井直樹<sup>†</sup> 尾花和昭<sup>†</sup>  
Sotaro Maejima Keisuke Tsunoda Midori Kodama Naoki Arai Kazuaki Obana

### 1. はじめに

商業ビルの消費エネルギー全体の 40%を空調システムが占めており[1], 施設運営の観点では空調システムの省エネ化が重要である。一方, 施設利用者が快適に感じる室内温熱環境を維持する運営もまた重要であり, 例えば主観的な冷温感 Predicted Mean Vote 値(以下, PMV)が, 空調に基づく建物温熱環境評価に用いられる[2]。これらのことから, ビル運営者としては省エネ性と快適性を両立した空調制御が理想的である。しかし, 一般的な商業ビルでは快適性や省エネ性の観点で最適な空調制御方法が不明であることや, 施設利用者からのクレームへの配慮から, 温度や風量等の設定ボタン, すなわち空調制御ボタンはほぼ一定である。具体的には, 建築物の管理基準に収まる範囲で, 経験的にクレームがないことを確認した少ない空調制御ボタンを, 季節毎に切り替える運用が主流である。そのため多くの商業ビルでは, これまで実施していない設定温度や風量の変化を含む空調制御方法, すなわち未知の空調制御ボタンを適用することで, 快適性や省エネ性が向上する余地がある。

快適性と省エネ性の両立に向けた空調制御方法として, 将来の室温を予測し, 予測から事前に制御内容を算出するフィードフォワード制御が挙げられる。フィードフォワード制御は, 一般的にビル空調で用いられる PID 制御[3]等と異なり, フィードバックによる制御の時間遅れがないため, 空調の過剰/過小を抑制する効果が期待できる。例えば, 快適性の報酬最大化に向けた空調制御ボタンを探索する深層強化学習により, 予測室温を入力することで, 快適性を最適化する空調制御ボタンを事前算出する手法が提案されている[4,5]。このような空調制御ボタンの算出に用いる快適性や省エネ性は, その算出精度が予測室温に依存するため, 室温予測の高精度化が重要である。特に, 様々な未知の空調制御ボタンを比較・検証するために, 空調のもっともらしい効果——例えば冷房の設定温度が室温より低い場合, その差分に比例して室温が低下する——を再現する室温予測が必要である。

室温予測は, データセンタなどの温熱環境の変動が少ない定常環境であれば, 室温変化の平均や分散がほぼ一定であるため, 比較的容易である。一方, 商業施設ではより困難である。これは, 不特定の人の往来による人自身の熱放射や外気流入などの影響がある非定常環境であり, 室温変化の平均や分散が時系列的に変化するためである。さらに, 商業ビルでは前述のように少ない空調制御ボタンにおけるデータのみ利用可能であり, データから観察できる空調の室温に対する効果は「空調が起動しているか否か」程度で

ある。このようなデータのみを基に, 空調のもっともらしい効果を再現する予測モデルの構築は困難である。

従来の室温予測手法として, 数値流体力学 (computational fluid dynamics; CFD) によるシミュレーション手法が挙げられる。しかし, 精度が測定困難な多数のパラメータに依存すること, 演算負荷が高いことが課題である。一方, 近年は機械学習による室温予測手法も広まりつつある。機械学習は CFD と比較して演算負荷も小さく, 必要なパラメータも少ないが, 学習データのバリエーションが少ないと予測結果が偏り, 未知パターンのデータに対する予測精度が低下する課題がある。

本稿では, 商業ビルのように不特定多数の人の出入りがあり, 少ない空調制御ボタンのデータのみ利用可能な対象環境における, 空調の最適制御実現を目指し, 室温や外気温, ビル内の滞在人数, 空調制御パラメータのデータを基に, 将来の非定常室温を予測する手法について述べる。具体的には, 入力データや学習アルゴリズムが異なる予測モデル群から, 特徴量寄与度と予測精度を考慮した指標により適切な予測モデル選択により, 機械学習手法の課題を克服する室温再現手法を提案する。特徴量寄与度を用いて予測モデルの評価を行うことで, 非定常環境において空調制御効果をもっともらしく反映した高精度な室温予測を行う予測モデルを選択し, 空調制御ボタンが少ないデータの学習のみで, 未知の空調制御ボタンにおいても非定常な室温予測を実現する。また, 商業ビルにおける実測データへ適用することで, 提案手法の有効性を示す。

### 2. 関連研究

室温予測手法として, 大きく分けて熱流体シミュレーション手法と機械学習手法が存在する。本章ではそれぞれの関連研究について述べる。

#### 2.1 熱流体シミュレーションによる室温予測

熱流体シミュレーションは数値流体力学(CFD)を用いる手法であり, 対象空間を 3 次元のメッシュに分割し, 空気の流入/流出の境界条件や, 壁や天井の熱伝導率などのパラメータを設定して, 各メッシュで流体流動を記述する偏微分方程式を解くことで, 温度などを算出する。CFD は, 建築の温熱環境評価や空調制御設計に向けた室温予測に利用されており, 誤差 0.5 度~1 度程度の室温予測を実現する手法が提案されている[6, 7]。

しかし, 対象空間の 3 次元寸法や温熱特性などの多数のパラメータが計算に必要あり, 対象空間によってはこれらの測定が困難な場合がある。そのため, 利用できる建物に限られる。また, 原理的に流体力学に則った膨大な計算を都度行うため, 強化学習等の逐次的計算手法と組み合わせると計算量が爆発する。すなわち, 対象の建物と, 組み合わせる手法の観点で, 適用範囲が限定される問題がある。

<sup>†</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  
NIPPON TELEGRAPH AND TELEPHONE CORPORATION  
NTT Smart Data Science Center

## 2.2 機械学習による室温予測

機械学習による室温予測は、施設特有のパラメータやそれらを用いた具体的なモデルを明示することなく、室温や空調制御情報などのデータを基に学習することで、自動的に予測モデルを構築する手法である。データセンタや個人住居など、多様な空間を対象に室温予測手法が提案・検証されている。MtibaaらはVAVやCAVを空調制御系に採用した各ビルを対象に、LSTMによる室温予測を問題として設定し、利用特徴量、入力データ時間幅、予測先時刻、予測時点数等のパラメータ組み合わせ毎に予測精度を検証した[8]。Songらは、室温や外気温、空調制御パラメータなどの相関分析を基に、対象空間における室温予測が非線形問題と定義したうえで、時点毎に室温予測に寄与する過去の時点の室温重みを自動選択する階層型 Attention 適用 GRU モデルを提案し、GRU や LSTM 以上に良い精度で予測が可能であることを示した[9]。Huangらは室温そのものの時系列変動と、空調制御効果による変動の分解に注目し、ARモデルでの室温予測後、予測値と空調制御パラメータをXGBoostモデルに入力することで、空調制御効果を反映した室温予測値を改めて算出し、次時点の予測時の入力としてフィードバックする、2段階逐次予測手法を提案した[10]。

これらの手法は対象環境で高精度な室温予測を実現しているが、不特定多数の人の出入りがある環境を対象として、少ない空調制御パタンのデータを学習に利用した室温予測の研究は、これまでなされてこなかった。

## 3. 要件と課題

### 3.1 問題設定

本節では、非正常環境における室温予測の要件を抽出するため、実環境導入を見据えた要求と制約事項を、問題設定として整理する。

まず、本稿において室温予測を行う対象環境は商業ビルなどの、不特定多数の人が出入りする施設である。このような空間では、人自身の熱放射や、人の移動に伴う外気流入によって、室温が非正常、非線形に変化すると考えられる。そのため室温変化予測にあたり、人流の影響を受けた非正常室温を予測できる必要がある。また、上述のように商業ビルでは少ない空調制御パタンのみ実施されるため、空調制御パタンが少ない学習データのみが利用可能だが、実運用を考えると学習データに存在しない未知の空調制御パタンに対応した予測ができる必要がある。

本稿では室温予測モデルは、最適な空調制御方法の算出への活用を前提とする。例えば、最適な空調制御方法を強化学習で算出する場合、強化学習エージェントの空調制御パラメータをアクションとして入力し、予測室温を出力する強化学習環境モデルとして、室温予測モデルは利用できる。そのために、単位時間毎に変動する空調制御パラメータの変動の影響を蓄積した予測室温を、単位時間毎に観測できる必要がある。具体的には、時刻 $t$ までの空調制御パラメータや室温データを入力して時刻 $t+1$ の室温を予測し、次に時刻 $t+1$ までの空調制御パラメータや室温データ(前時刻に予測された室温データを含む)を入力して時刻 $t+2$ の室温を予測する、というように、過去の室温予測を用いた入力データの逐次更新と予測が必要である。

室温は季節変動を持つ外気温の影響を受けるため、季節別でモデルを作り分ける必要がある可能性が高いが、長期間の学習データが必要になると、データ取得期間中に季節が移り替わり、システムの稼働開始が一年後になるなど、機会損失の問題が発生しうる。データ取得後に早期にシステムとして運用するため、最大でも1か月程度の少量データのみから室温が予測できることが望ましい。

室温予測手法の適用範囲という観点では、多様な環境で共通的に取得可能なデータのみ利用することが望ましい。どのような環境でもセンサを設置すれば温度は計測可能であり、また空調制御システムは存在する前提のため、空調制御の設定値も取得可能と考えられる。一方、建物自体の詳細な設計データ等がないため建物固有の温熱特性パラメータが取得できない、また空調制御システムの内部の正確な制御則がブラックボックスのため空調制御の任意の設定値に対する実現値——例えば冷房設定温度に対して実際に吹く風の温度——は入手できない可能性がある。そのため、室温予測にこれらのデータを利用しないことが望ましい。

### 3.2 要件

上記の問題設定をまとめると、本稿における室温予測の要件は下記の通りである。

- 人流の影響を含めた非正常な室温予測ができること
- 少ない空調制御パタンのデータの学習のみで、未知の空調制御パタンに対応した予測ができること
- 単位時刻毎に入力される空調制御パラメータの影響を反映した室温を予測し、予測値を該当時刻の予測における入力値として逐次更新すること
- 学習データの期間が数週間～1か月程度であること
- 建物固有の温熱特性パラメータ、空調制御の実現値を利用しないこと

### 3.3 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。熱流体シミュレーションによる室温予測は、上述のように対象施設によっては取得不可能な多数のパラメータが必須である上、大きな計算時間を必要とするため、多様な環境への適用という観点で、要件を満たさない。

一方で、機械学習による室温予測は、学習さえ完了すれば計算時間は短く、建物固有の温熱特性パラメータを必須としない。この手法の課題は、少ない空調制御パタンのデータを用いて学習した室温予測モデルが、学習データに存在しない未知の空調制御パタンにおいて、空調のもっともらしい効果を反映した予測を行う保証がないことである。豊富な空調制御パタンを含む大量の学習データが利用できれば、空調制御パタンの室温に対する影響を真に近い形で学習することが期待できるため、学習データに存在しない空調制御パタンに対しても予測精度が低下する心配は少ない。しかし、上記要件から、一般的に空調制御の設定値よりも変化パタンが多い実現値が利用できず、学習データの量も少ないため、単純に予測モデルを構築してもそのような学習ができる可能性は低い。利用する学習アルゴリズムや特徴量の選択、特徴量の加工の組み合わせで対応できる可能性はあるが、各要素の大量の組み合わせを用意してそ

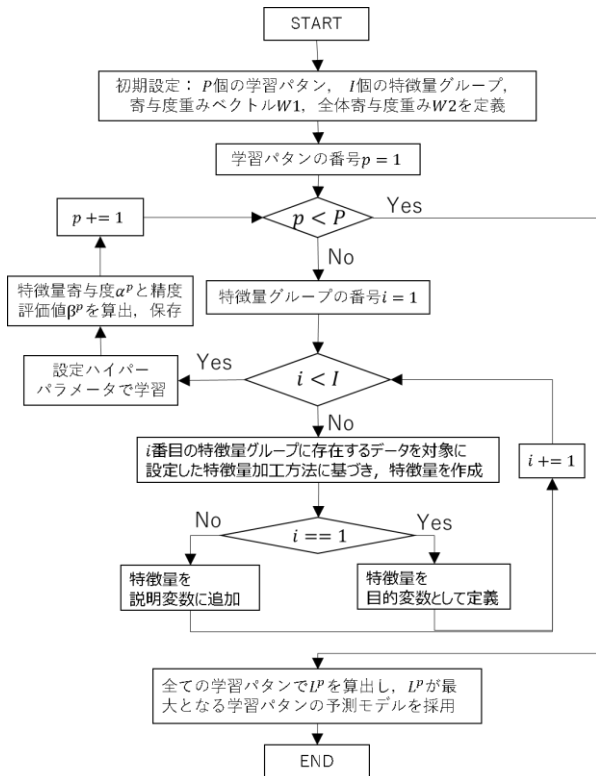


図1 予測モデル選択の処理フロー

それぞれ学習して所望の予測モデルを探索するなど、作業の時間がある。

別のアプローチとして、階層的 Lasso[11]のように予測に寄与させる特徴量の順序などをパラメータとして指定する手法により、空調制御パラメータが室温予測に寄与する予測モデルを構築することも考えられる。しかし、このような手法は線形モデルが前提であり、非定常環境で非線形に変化する室温の予測には適さない。逆に言えば、非定常、非線形に変化する室温の予測モデルに適用可能な、高精度かつ空調制御設定値の影響をもっともらしく反映する予測モデルが自動選択できれば、要件を満たすことができる。

以上の内容から本稿における課題は、不特定多数の人が出入りする非定常環境を対象に、データ量や空調制御パターンが少ない学習データを用いて、高精度かつ空調制御設定値のもっともらしい効果を反映する室温予測モデルを、自動で選択することとする。

#### 4. 提案手法

上記課題を解決するため、本稿では特徴量寄与度を用いて、学習アルゴリズム、特徴量、特徴量の加工方法が異なる予測モデル群から適切な予測モデルの自動選択手法を提案する。特徴量寄与度は、特徴量が予測に及ぼす影響を定量化した値であり、例えば決定木モデルにおける各特徴量による学習データ分割時の情報利得和を指す Feature Importance[12]、特徴量のランダム並び替え時の予測精度変化から逆説的に特徴量の重要度を評価する Permutation Importance[13]が提案されている。従来これらの値は、予測モデルの予測根拠説明や、重要度が高い特徴量の抽出による精度向上と計算高速化への活用が主であるが、本稿では予測モデル間で特徴量寄与度を比較できるように大きさを

スケールし、予測精度と組み合わせた予測モデル評価指標として活用する。これにより、候補の予測モデル群から、空調制御設定値の特徴量寄与度が大きく予測精度が高い予測モデルを選択することで、課題解決を試みる。

本稿で対象とする予測モデルを、式(1)のように定める。

$$y_t = f(X_{t-m}, X_{t-2m}, \dots, X_{t-Wm}, Z_t, Z_{t-m}, \dots, Z_{t-Wm}) \quad (1)$$

$y_t$ が目的変数、 $X_t$ が予測対象時刻の値が予測時に利用不可能な説明変数、 $Z_t$ が予測対象時刻の値が予測時に利用可能な説明変数である。例えば時刻  $t$  の室温予測において、室温はそれまでに観測・予測された時刻  $t$  以前の値が利用可能なため  $X_t$  に該当し、空調制御設定値は時刻  $t$  の設定値を把握可能なため  $Z_t$  に該当する。また、 $W$  はウィンドウ数、 $m$  は時間間隔とする。説明変数の加工方法や  $W$ ,  $m$  を変更することで、選択候補となる予測モデルを構築する。

全体処理フローを図1に示す。まず、各特徴量に対して識別子を付与する。このとき、時系列は異なるが本質的には同じ特徴量には同じ識別子を付与する。同じ識別子を持つ特徴量の集合を、特徴量グループと定義する、例えば予測時刻から30分前と60分前の室温は同じ特徴量グループに属す。また予測モデルの構築に必要なパラメータの組み合わせを学習パターン  $p$ 、とそれぞれ定義する。学習パターンの構成要素を下記に示す。

- **学習アルゴリズム:**  
予測モデル構築に向けた学習に用いるアルゴリズム。
  - **ハイパーパラメータ:**  
学習アルゴリズムの制御に用いるパラメータ。パラメータの値は一意に確定していても、複数の候補からの探索を明示しても良い
  - **特徴量加工方法:**  
特徴量に対する加工方法。例えばある特徴量の階差化、他特徴量との四則演算、時間間隔  $m$  など。加工した特徴量の特徴量グループの所属も同時に指定。
- 予測モデル選択に向けた初期設定として、上記パラメータの組み合わせを事前に定義する。また、 $I$ 個の特徴量グループ、特徴量グループの中での重視する寄与度を規定する寄与度重みベクトル  $W1$  と、 $0$ 以上のスカラ値である全体寄与度重み  $W2$ 、平均絶対誤差 (MAE) の逆数など予測精度を表す精度評価値  $\beta^p$  の計算方法、を事前に設定する。ここで  $i=1$  の特徴量グループは目的変数、それ以外の特徴量グループは説明変数と定義する。式(2)に寄与度重みベクトル  $W1$  の定義を示す、 $w_i$  は  $i$  番目の各特徴量グループの重みである。

$$W1 = [w_1, w_2, \dots, w_I] \quad (0 \leq w_i \leq 1, \sum_{i=1}^I w_i = 1) \quad (2)$$

初期設定のあと、 $p$  番目の学習パターンにおいて、 $i$  番目の各特徴量グループの寄与度  $c_i^p$  を式(3)で算出する。 $d_i^p$  は  $i$  番目の各特徴量グループに属す全特徴量の特徴量寄与度の平均値である。

$$c_i^p = 100 \times \frac{d_i^p}{\sum_{i=1}^I d_i^p} \quad (3)$$

式(4)より、予測時刻から30分前と60分前の室温など同じ特徴量グループに属す特徴量の寄与度をまとめ、学習パターンごとに必ずしも同じとは限らない特徴量寄与度のスケー

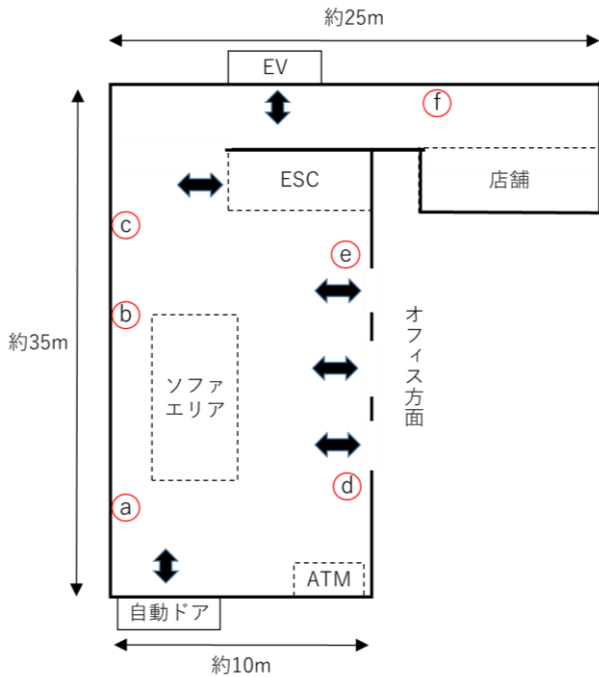


図2 対象空間イメージ

ルを合わせることで、学習パターン間で比較可能になる。次に、式(4)で示す寄与度ベクトル  $C^p$  と、転置した  $W1$  の積を取ることで、式(5)のように寄与度評価値  $\alpha^p$  を算出する。

$$C^p = [c_1^p, c_2^p, \dots, c_l^p] \quad (4)$$

$$\alpha^p = C^p \cdot W1^T \quad (5)$$

最後に、算出した  $\alpha^p$  と、事前に定義した方法で算出した  $\beta^p$  を記録する。ここで算出した  $\alpha^p$  と  $\beta^p$  はスケールが必ずしも一致しないため、直感的にその大きさを比較することが難しい。そこで上記処理を全学習パターンで実行した後、(6)式に示すように  $\alpha^p$  をスケールしたうえで、各学習パターンで  $p$  番目の学習パターンの予測モデル評価値  $L^p$  を算出し、最も  $L^p$  が大きい予測モデルを選択する。このようにすることで、特徴量寄与度と予測精度の優先度合いを  $W2$  で直感的に定めるのみで、学習モデルの選択が可能になる。

$$L^p = \frac{\sum_{p=1}^p \beta^p}{\sum_{p=1}^p \alpha^p} \cdot W2 \cdot \alpha^p + \beta^p \quad (6)$$

## 5. 実データを用いた評価

### 5.1 対象空間について

本節では、提案手法を適用する商業ビルの空間について述べる。評価に用いた対象空間を図2に示す。対象空間はオフィスビルのロビーであり、オフィス方面へ繋がるゲート、他フロアや店舗へアクセスするエスカレーター・エレベータ方面への通路、室外直通の自動ドアの出入口が設置されている。そのため、これらの出入口を利用して不特定多数の人が行き交う。またソファエリアも存在し、移動せずに着席する人がいる場合もある。

制御対象の空調システムとして、温風や冷風を生成するAHU(Air Handling Unit)と、AHUから供給された風を室内に送る VAV(Variable Air Volume)が2つ設置されており、送

表1 探索ハイパーパラメータの一覧

モデル	パラメータと探索範囲(始点, 終点, 間隔)
ElasticNet	$\alpha$ : [0.2, 0.8, 0.1] l1_ratio: [0.2, 0.8, 0.1]
LSTM	ノード数: [200, 500, 100] Dropout率: [0.2, 0.6, 0.2] 再帰Dropout率: [0.2, 0.6, 0.2]
LightGBM	max_depth: [5, 11, 2] num_leaves: [30, 60, 10] bagging_fraction: [0.5, 0.9, 0.2]

表2 提案手法のパラメータ

名称	値
寄与度重みベクトル $W1$	[0.3, 0.2, 0.1, 0.3, 0.1] (左から室温, 外気温, 人流, 空調設定値, 営業時間フラグ)
寄与度重み $W2$	1.0
時間間隔 $m$	60分
ウィンドウ数 $W$	6
連続値特徴量の階差化	時間間隔 $m$ で実行
空調設定値と室温の差分特徴量	空調設定値を, 時刻 $t$ の空調設定値から時刻 $t-m$ の室温を引いた値に差し替え

風温度を規定する給気温度目標値, 給気温度や室温に基づいて送風量を制御する室内設定温度 (各 VAV で独立) の2種類である。

### 5.2 利用データ取得

提案手法を評価するため、学習データおよびテストデータを10分間隔で取得した。図2中のa~fの6測定点において、室温を計測・取得した。室温は、目的変数  $y_*$ 、説明変数  $X_*$  として活用する。また LRF センサを用いてフロア内の滞在人数を計測し、気象予報サービスを用いて施設の所在地の1kmメッシュ区間の実測外気温を取得した。これらの値は説明変数  $X_*$  として活用する。

予測対象時刻の値が利用可能な説明変数  $Z_*$  として、給気温度目標値, 2測定点の VAV それぞれの室内設定温度, 店舗や ATM の営業時間のデータを取得した。営業時間データは、営業時間内/外を示す one-hot フラグの時系列データに変換して利用する。

### 5.3 特徴量の加工方法

本節では、提案手法においてその適用の有無を判断する、特徴量の加工方法について述べる。

一つ目に、空調設定温度と室温の差分を取る加工、すなわち相対的な温熱差を、空調設定温度の特徴量として置き換える方法である。空調システムは、一般的には室温との相対的な関係により、その効果が規定されると考えられる。例えば、同じ設定温度 25度であっても、室温が 28度なら室温低下、室温が 20度なら室温上昇に作用する。そのため、機械学習モデルがこのような室温と空調設定温度の相互作用を学習できれば、空調のもっともらしい効果を反映した

表3 全測定点・全時点に対する予測誤差

手法	平均絶対誤差	最大誤差	誤差標準偏差	比較手法との差	提案手法との差
比較手法1	0.48	2.5	0.31	False	True
比較手法2	0.48	2.1	0.34	False	True
比較手法3	0.5	2.2	0.36	False	True
提案手法	0.35	1.8	0.28	True	-

表4 MAEに対する多次元配置分散分析

	平方和	自由度	F値	p値
手法	18.5	3	60.5	*
予測日	9.6	2	47.3	*
測定点	16.8	5	32.9	*
予測日×測定点	8.4	10	8.2	*
手法×予測日	30.3	6	49.6	*
手法×測定点	7.2	15	4.7	*

(\*:  $p < 0.01$ )

予測に繋がると言える。しかし、本稿の問題設定では、空調制御パターンが少なく、空調の実測温度ではなく設定温度のデータしか利用できないため、単純な空調設定温度の特徴量からは空調のもっともらしい効果を学習できない可能性が高い。そこで、このような特徴量加工により、空調制御パターンが少ない場合でも、室温の変化パターンをもとに、室温に対する空調の相対的な温熱効果パターンを多様かつ明示的に表現し、空調効果をもっともらしく学習できる可能性がある。

二つ目に、室温階差を取る加工方法である。一般的に機械学習モデルでは、学習データとテストデータを含めて目的変数の分布が不変であることを前提としている。室温や人流のような非定常的な時系列データを無加工で学習すると、データの分布や生成過程の実態に合わない学習が行われ、予測精度が低下する可能性がある。そこで、室温や人流などの連続値の時系列データに対し、階差加工を行う。階差を取ることで、定常的な時系列データになり、上記の問題を回避できる。また、目的変数を室温階差に置き換えることで、例えば28度から29度の室温変化が、24度から25度の室温変化と等価になる。そのため、目的変数の予測パターン数が低減し、モデルのバリエーションを低減する効果も期待できる。

#### 5.4 評価方法

前節で述べたデータを利用し、予測モデルを学習し、室




図3 各予測日の予測誤差




図4 各測定点の予測誤差

温を予測し、その効果を評価する。

本稿においては、2020年8月11日～30日の20日分のデータをを用いた。テストデータは、オフィスや店舗を訪れる人が多い平日である8月25～27日の3日間とし、各日付以外で学習して対象日を予測する leave-one-out 法を用いる。テストデータに対し、空調運転期間における予測精度を平均絶対誤差で検証する。テストデータ期間のみ、それ以外の期間と異なる設定温度で空調システムを運用した。

予測モデル選択のための初期設定として、精度評価指標の計算式を、予測値と実測値の平均絶対誤差の逆数にした。また、特徴量寄与度として SHAP 値[14]を利用し、特徴量グループ数を6、学習アルゴリズムは ElasticNet[15]、LightGBM[16]、LSTM[17]の3種類とした。特徴量グループは室温、外気温、人流、空調設定温度、営業時間フラグの5種類とした。ハイパーパラメータは表1に示すものを候補とし、学習アルゴリズム毎にグリッドサーチを行う。特徴量加工方法として、時間間隔  $m = 10 \sim 90$  分、ウィンドウ数  $W = 3 \sim 9$ 、連続値特徴量の階差化の有無、空調設定温度と室温の差分化の有無、を用意した。表2に選択された提案手法のパラメータを示す。寄与度重みベクトル  $W1$  は、空調設定や外気温など一般に室温への影響が大きい変数の値を相対的に大きくした。寄与度重み  $W2$  は、0.5~1.5の範囲(刻み幅 0.25)でそれぞれ選択した予測モデルでテストデータの平均絶対誤差を算出し、最も小さい値になった1.0を採用した。その他のパラメータはその際に選択された予測モデルの値である。

評価においては、以下の4つの手法を比較した。

- (比較手法1) ElasticNet
- (比較手法2) LightGBM
- (比較手法3) LSTM
- (提案手法) 選択された予測モデル

比較手法では従来の多くの室温予測手法のように特徴量加工は行わず、 $m$ と $W$ は提案手法と同じ値とした。




図5 予測結果サンプル (8/25 c 測定点)




図7 予測結果サンプル (8/27 f 測定点)




図6 予測結果サンプル (8/26 b 測定点)

いずれの手法も、式(1)に則った目的変数と説明変数の構成で学習する。また予測室温は、該当該時刻の予測に用いる入力値として逐次更新する。さらに、提案手法では連続値である室温は階差を取るため、予測後に初期室温と室温階差予測値の累積を合算し、室温予測値を算出した。

各予測日で算出した平均絶対誤差に対して、多次元配置分散分析を行い、手法、測定点、予測日の3要因の主効果とそれらの交互作用の有無を確認した。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。

最後に、各手法が空調のもっともらしい効果を学習しているかを確認するため、テストデータにおける給気温度目標値および室内設定温度の終日の値を-2 ~ +2度の範囲で仮想的にシフトさせた場合で予測を行った。

## 5.5 評価結果

表3に各手法の全測定点・全時点に対する予測誤差、表4に平均絶対誤差に対する多次元配置分散分析の結果を、それぞれ示す。表4において、手法の主効果が認められたため、事後検定としてTukey-Kramer法による多重比較検定を行い、提案手法が全ての比較手法に比べて、平均絶対誤差が有意に小さいことが示された。

各手法における各予測日の平均絶対誤差を図3に示す。表3において予測日の主効果および手法と予測日の交互作用が認められたため、事後検定として予測日ごとの手法間

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た結果、25,27日では有意差が認められた。

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4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ため、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行い、a~eの測定点で有意差が認められた。

各手法による室温予測結果サンプルを図5~7に示す。また、給気温度目標値および室内設定温度のシフト時の室温予測結果を図8、各測定点および各日付の給気温度目標値および室内設定温度の終日のシフト値に対するセンサ温度と予測温度の差分平均値を図9に示す。最後に、各手法で標準化した特徴量寄与度を図10に示す。

## 6. 考察

### 6.1 手法間の予測誤差比較

表3および4より、提案手法により選択されたモデルは、比較手法より小さい誤差、標準偏差であり、より安定して高精度な室温予測が可能であることがわかる。さらに、前章で述べた多重比較検定の結果から、予測誤差の小ささの有意性が示された。具体的には、図5に示すように、設定温度の急激な変化が発生する8時、10時、14時、17時などにおいて、提案手法は比較手法と比べると、急激な室温変化に高精度に追従できていることが確認できる。

この結果の要因として、5.3節で述べた2種類の特徴量加工の影響が考えられる。提案手法では空調設定温度と室温の差分を取ることで特徴量の変化パターンを拡張することで、空調と室温の相対的な関係から空調効果をもっともらしく学習し、精度が向上したと考えられる。また、提案手法では非定常であった室温や人流に対して1時間の階差を取ったが、この値にADF検定を実施すると定常であることを確認した。すなわち、提案手法は時系列データの自己相関や周期性の学習への悪影響が低減する適切な階差化の時間間隔を選択した可能性がある。

### 6.2 各予測日の予測誤差比較

表4より、予測日の主効果と、手法と予測日の交互作用が存在することから、手法と予測日により平均絶対誤差に有意な差があることが示された。図3に記載されるTukey-Kramer法による多重比較検定の結果から、8/25,27日では、

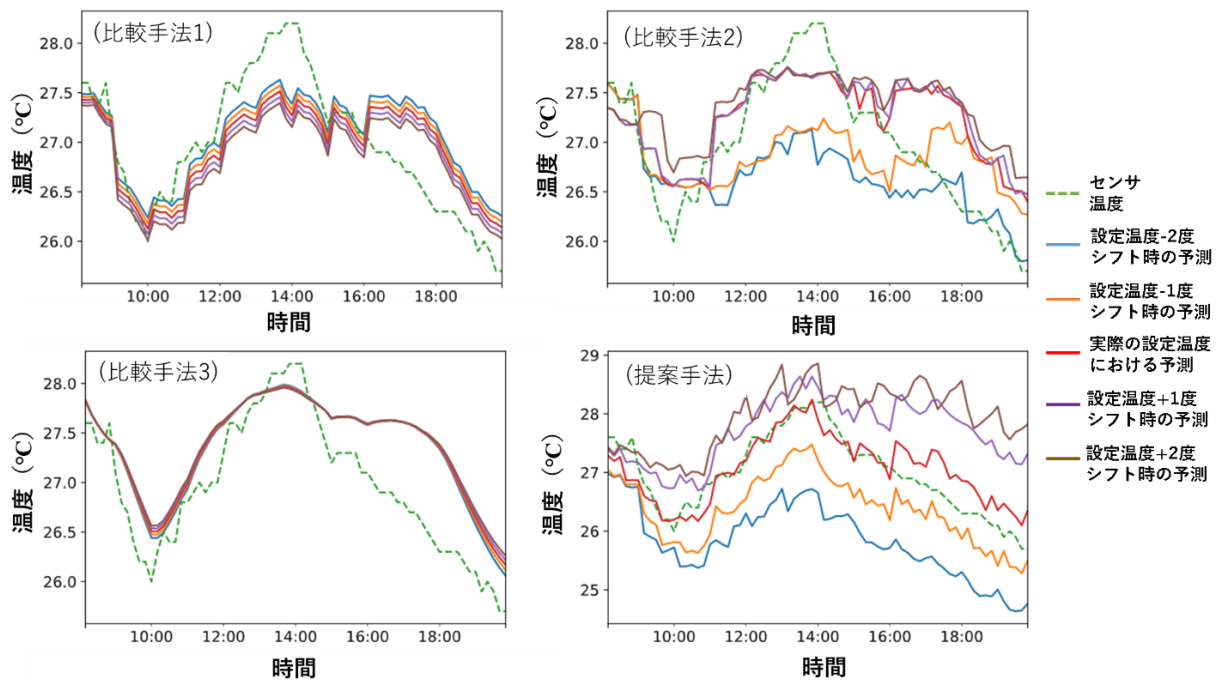


図8 8/25 測定点cにおける給気温度目標値および室内設定温度のシフト時の結果サンプル

提案手法が比較手法と比べて予測誤差が有意に小さいことが示された。図6の8/26の予測結果を見ると、提案手法は10時の温度の急低下には追従したものの、13時頃の急上昇や15時以降の急低下に対しては、0.5~1度程度の誤差が発生している。一方で、比較手法3は平均値に近い予測になったため、18~20時頃において予測誤差が相対的に小さくなっており、この差により提案手法と比較手法3の誤差に有意差が認められないと判定されたと考えられる。提案手法の誤差が26日に比較手法3と比較して有意に小さいと認められない原因として、今回のデータおよび予測モデルにおける未知の空調制御パターンへの対応の限界が考えられる。図6の15時頃の給気温度目標値の短期間での急低下・急上昇は未知の空調制御パターンであるが、ここまで大きい急変動には追従しきれず、今回のデータや予測モデルの限界だったと考えられる。また、18時前後の温度上昇が比較手法の精度向上に結果的に寄与したことも要因の一つであるが、この時間は空調動作の変動や外気温の上昇もなく、人流も少なかったため、データ上では温度が上昇する要因が見当たらなかった。未取得データである対象空間付近の風速、日射量等が影響した可能性もある。

### 6.3 測定点間の予測誤差比較

表4より、予測日の主効果と、手法と測定点の交互作用が存在することから、手法と測定点により平均絶対誤差に有意な差があることが示された。図4に示すTukey-Kramer法による多重比較検定の結果から、a~e測定点では、提案手法が比較手法と比べて予測誤差が有意に小さいことが示された。図7を見ると、f測定点では比較手法2が最も良い精度であり、提案手法の予測精度は低い結果である。

この要因として、店舗空調の影響が考えられる。f測定点の温度センサは店舗前に設置されていたが、店舗はビルとは系統が異なる個別空調を持っており、その影響を受けている可能性が高い。提案手法は給気温度目標値の挙動に

追従した結果、このような外乱によって精度が低下したと考えられる。一方、比較手法からは空調のもっともらしい効果を学習していないゆえに、予測が偶然外乱方向に寄っていたことで、相対的に提案手法に対して精度が向上する形になり、提案手法との予測誤差の違いに有意差が表れなかったと考えられる。

### 6.4 空調温度設定値の変更時の予測結果比較

図8を見ると、比較手法1,3では空調設定温度をシフトさせた場合、予測室温がほぼ変化しないことがわかる。この結果から、比較手法1,3では空調設定温度の影響を予測値に反映できず、テストデータ以外の様々な未知の空調制御パターンでは予測精度が低下する可能性が高い。比較手法2も、実際の設定温度~+2度のシフト範囲ではほぼ予測室温は変化せず、同様のことが言える。一方で提案手法の場合、空調設定温度のシフトに予測結果が上下に追従している。正解データが存在しないため、予測結果が必ずしも高精度とは言えないが、比較手法らと比べると空調のもっともらしい効果を学習した可能性が高い。図9から提案手法のみ空調設定温度の変化に予測値が追従していることもわかる。

この結果の要因について考察する。比較手法1は、回帰式の切片が大きく、空調設定温度の増減が予測値に影響しなかった。また設定温度の影響も正負が逆転していることも図9からわかる。比較手法2は、特徴量の値に閾値を設定して予測値が分岐する決定木モデルの構造上、今回のように少ない空調制御パターンのデータでは、空調設定温度の決定木内での分岐は数パターンに留まる。その結果、空調設定温度と室温の細かい相互作用をモデル内で再現できなかったと考えられる。比較手法3では室温の寄与度が高く、室温の周期性と自己相関によって室温が過度に重視され、空調効果を学習しなかったと考えられる。提案手法は、図10を見ると給気温度目標値の特徴量寄与度が大きい。給気




図9 各手法の空調設定温度変化に対する予測室温とセンサ温度の差分平均

温度目標値は室内設定温度と比べて変動が大きく、一般的に室温への影響が強いため、そのもっともらしい効果が室温との差分変換により表現された結果と考える。

## 7. 結論

本稿では、商業ビルなどの不特定多数の人が出入りする非定常環境における空調の最適制御実現に向けた、少ない空調制御パタンのデータによる学習のみで非定常環境における室温予測を目的とし、特徴量加工や学習アルゴリズムの組み合わせから、予測精度と特徴量寄与度に基づき適切な予測モデルを選択する手法を提案した。本稿の貢献は以下の通りである。

- 不特定多数の人が出入りする商業ビルの空調制御を見据えた室温予測に必要な要件として、人流の影響を考慮する点、学習データに存在しない空調制御パターンを考慮する点、空調制御パターンが少ない学習データで予測できる点、建物固有の温熱特性パラメータや空調制御の実現値を利用しない点を明確化した。
- 上記要件から、予測精度と特徴量寄与度を用いて予測モデルを選択に基づき、空調制御パターン数が少ないデータの学習のみで未知の空調制御パターンにおける非定常室温の予測手法を提案した。
- 提案手法を実際の商業ビルで計測した実データに適用した結果、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。
- テストデータの空調設定温度を増減した場合の予測結果から、空調制御パターンが少ないデータでの学習であっても、相対的な温熱性の考慮や、連続値の時系列データの階差化により、未知の空調制御パターンにおいて空調のもっともらしい効果を加味した室温予測ができる可能性を示唆した。

今後の課題としては、より高度な空調システムがある空間における検証や、予測モデル選択における特徴量寄与度と予測精度の最適重みの自動設定方法の検討、風速や日射など更なるデータの活用、より多様な空調制御パターンに対する予測精度検証が挙げられる。

### 参考文献

- [1] 一般社団法人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”, [https://www.eccj.or.jp/office\\_bldg/01.html](https://www.eccj.or.jp/office_bldg/01.html) (最終閲覧日:2021.4.6).
- [2] 公共社団法人 日本冷凍空調学会, <https://www.jsrae.or.jp/annai/yougo/66.html> (最終閲覧日:2021.4.6).




図10 各手法の標準化した特徴量寄与度

- [3] 高草木明, “定風量空調設備における室温単位応答と目標値追従特性からの PID 制御パラメータに関する研究”, 空気調和・衛生工学会論文集, No.83 (2001).
- [4] 牧野重朗, 斎藤輝幸, “CFD と強化学習による空調最適化制御に関する研究”, 空気調和・衛生工学会論文集, No.83 (2001).
- [5] Donald Azuatalama, Wee-Lih Lee, Frits Nijs, Ariel Lieberman, “Reinforcement learning for whole-building HVAC control and demand response whole”, Energy and AI, Vol. 2 (2020).
- [6] 谷口剛志, 金田一清香, 西名大作. “エネルギーシミュレーションと CFD の連成による吹き抜け空間を有する住居を対象とした温熱環境解析手法の精度検証”, 空気調和・衛生工学会大会, 平成 30 年度大会 (名古屋) 学術講演論文集, 第 6 巻, 温熱環境評価編 (2018).
- [7] 齋数由香子, 近田 智洋, 原山 和也, “室内環境計測データと CFD 解析を活用した空調制御に関する研究 (その 1) 3 次元温熱環境可視化システムの構築”, 空気調和・衛生工学会大会, 平成 30 年度大会 (名古屋) 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 (2018).
- [8] Fatma Mtibaa, Kim-Khoa Nguyen, Muhammad Azam, et al, “LSTM-based indoor air temperature prediction framework for HVAC systems in smart buildings”, Neural Computing and Applications, Vol. 32 (2020).
- [9] Jiancai Song, Guixiang Xue, Yunpeng Ma, et al, “An Indoor Temperature Prediction Framework Based on Hierarchical Attention Gated Recurrent Unit Model for Energy Efficient Buildings”, IEEE Access, Vol.7, (2019).
- [10] Yongchao Huang, Hugh Miles, Pengfei Zhang, “A Sequential Modelling Approach for Indoor Temperature Prediction and Heating Control in Smart Buildings”, Neural Information Processing Systems (2020).
- [11] Jacob Bien, Jonathan Taylor, Robert Tibshirani, “A lasso for hierarchical interactions”, The Annals of Statistics, Vol. 41, No. 3 (2013).
- [12] L. Breiman, J. Friedman, R. Olshen, and C. Stone, “Classification and regression trees”, Routledge (1984)
- [13] André Altmann, Laura Toloşi, and Oliver Sander, et al “Permutation importance: a corrected feature importance measure”, Bioinformatics, Vol. 26, Issue. 10 (2010).
- [14] S. M. Lundberg, et. al., “A Unified Approach to Interpreting Model Predictions”, Neural Information Processing Systems (2017).
- [15] Hui Zou, Trevor Hastie, “Regularization and variable selection via the Elastic Net” Journal of the Royal Statistical Society, Series, B 67 (2005).
- [16] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, et al, “LightGBM: A Highly Efficient Gradient Boosting Decision Tree”, Proceedings of the 31st International Conference on Neural Information Processing Systems, pp. 3149–31577 (2017).
- [17] S. Hochreiter, J. Schmidhuber, “Long short-term memory”, Neural Computation, vol.9, Issue.8, pp1735-1780, November (1997).