

オフィスビルの空調制御に向けた深層学習による室内温度予測

Deep Learning-based Indoor Temperature Prediction for Air Conditioning Control in Office Buildings

檜山 優毅[†] 野口 渉[‡] 山本 雅人^{§*} 宮田 大輔^{*} 山本 亨[‡]

Yuki Hiyama Wataru Noguchi Masahito Yamamoto Daisuke Miyata Toru Yamamoto

1. はじめに

近年、建物のエネルギー消費を削減するための取り組みが重要視されている。特に、空調システムは大きなエネルギー消費を占めるため、その運用効率化によるエネルギー削減が期待されている。一方で、室内の温熱環境を快適に維持することも重要な要素であり、空調制御には省エネルギー性と快適性の両立が求められる。

関連研究として商業ビルや複数の部屋をもつ住宅環境で省エネルギー性と快適性を両立する空調制御のために深層強化学習を利用した研究がある[1, 2]。これらの研究はシミュレーション環境内の建物の空調制御の強化学習を行っており、学習済みモデルを実世界の特定の建物に適用するためには、実環境での強化学習によるモデルの再調整が必要となる。実環境での調整には実環境の設備操作が必要であるが、予測や制御のミスにより、安全性や設備破損などのリスクが伴う。そこで、著者らのグループは過去に、実際のオフィスビルの空調関連データを用いて未来の室内温度を予測し、予測結果に基づいて制御を行う研究[3]を行った。その過程で、空調関連データと室内温度の変動との関係性が不明瞭な場合に、深層学習によりデータから関係性を学習することで未来の室温変動を予測する手法を開発した[4]。この研究では、特定のオフィスビルのみを対象にしていた。

本研究では、[4]と同様に、実環境から計測できるデータを活用して深層学習モデルを構築することで、特定のオフィスビルだけでなく、他のビルや環境にも対応可能なモデルの開発を目指す。本研究でも特定のオフィスビルを対象としているが、[4]とは異なるオフィスビルを対象としている。また、未来の制御データをモデルの入力に組み込むことで、空調制御が将来の室内温度に与える影響を考慮する。これにより、未来の制御計画を考慮した温度予測の精度が向上することを目指す。実験では、実データを用いて各部屋における現在時刻から 1 時間後の室内温度を予測する深層学習モデルを構築する。本モデルの予測性能をルールベースモデルとの比較により評価し、その有用性を確認する。

[†] 北海道大学大学院情報科学院

Graduate School of Information Science and Technology, Hokkaido University

[‡] 北海道大学数理・データサイエンス教育研究センター

Education and Research Center for Mathematical and Data Science, Hokkaido University

[§] 北海道大学大学院情報科学研究院

Faculty of Information Science and Technology, Hokkaido University

^{*} 北海道大学人間知・脳・AI 研究教育センター

Center for Human Nature, Artificial Intelligence, and Neuroscience, Hokkaido University

^{*} 広沢電機工業株式会社

HIROSAWA ELECTRIC Co.,Ltd.

^{*} 株式会社インティ

Intee Corporation




図 1 提案モデルの概略図

2. 深層学習による室内温度予測

本節では、データセット及び深層学習による予測モデルの詳細について述べる。このモデルは現時刻との室内温度の差分、つまり室内温度の変化量を出力とする。この出力に現時刻の室内温度を加えることで、1 時間後の室内温度を推定する。

2.1 データセット

日本の特定のオフィスビル内の 6 部屋 (A ~ F) から得られた空調関連データを対象としている。これらのデータは、2019 年、2021 年、2022 年の 3 年間に渡り 10 分間隔で収集された。各部屋は建物の階数や位置、使用用途が異なることを特徴としている。空調関連データは、センサーによる観測データと制御データの 2 種類から構成されている。具体的な項目とそのカテゴリは表 1 に示すとおりである。これらのデータは、全ての部屋で 0 ~ 1 に正規化した。また、空調関連データの一部の日時には、欠損があるが、これらの欠損データは除外している。

表 1 観測データと制御データの詳細

	データ項目
観測データ	外気温度, 外気湿度, 室内温度
制御データ	室内設定温度, 発停 STS

2.2 ネットワークの設定

本研究で用いるモデルは図 1 に示すような 1 つの入力層、3 つの中間層、1 つの出力層から構成される 5 層ニューラルネットワークである。モデルの入力データは、時系列性と空調制御の影響を考慮するため、現時刻から過去 24 時間分の空調関連データ (144×5 変数) と未来 1 時間分の制御データ (6×2 変数) を含めた。つまり、空調制御が室内温度の変化にどのような影響を与えるかを考慮している。さらに 24 時間を単位円上の座標で表現した現時刻データ (2 次元) を追加し、計 734 次元とした。

これに基づき、入力層は 734 ノードをもち、中間層はそれぞれ 128 ノード、出力層は 1 ノードで室内温度の変化量の予測値を出力する。活性化関数には sigmoid を使用した。

本研究では、2019 年と 2021 年のデータを訓練データとし、2022 年のデータをテストデータとして使用した。バッチサイズは 1024 とし、オプティマイザには Adam を採用した。学習においては、学習率を 10^{-4} と定め、300 エポックの学習を行った。また、個々の部屋が異なる環境特性と空調の影響をもつことから、各部屋に対応するネットワークモデルは独立して学習した。

3. 予測結果

モデルは各部屋について、ランダムな初期パラメータからの学習を 5 回繰り返して行った。5 回の学習試行について、テストデータに対する平均絶対誤差 (MAE) と許容範囲内達成率の平均値によってモデルの性能を評価した。さらに、提案モデルの効果をより具体的に評価するため、基準として現在の室内温度が 1 時間後も変わらないと予測するルールベースのモデル (予測 0) を設けた。これらのモデルを比較し、深層学習モデルの有用性を検証する。

3.1 予測誤差の評価

まずは予測誤差として、テストデータに対する予測の絶対値誤差 (MAE) を算出した。表 2 に各部屋に対する深層学習モデルと予測 0 モデルの予測誤差を示す。この結果から、深層学習モデルが全ての部屋において予測 0 モデルよりも低い誤差を示し、その性能の優位性が確認できた。

さらに、特定の日の室内温度予測結果を折れ線グラフとして示した。図 2 には、部屋 E の 1 日分の深層学習モデルと予測 0 モデルによる予測、及び実際の室内温度が示されている。図 2 から、深層学習モデルが 7~9 時及び 19 時以降の急激な温度変化に対応できていることが視認できる。これらの時刻は業務開始と終了の時刻に相当し、深層学習モデルが空調稼働及び停止を学習していると解釈できる。一方で、11~14 時の間に見られる日中の急激な温度変化には十分に対応できていない。この結果は、現行の運用においては室内温度設定の変動が少ないため、設定変更がない状況下での急激な室内温度変化を学習できていない可能性を示唆している。このような温度変動の要因を解析し、入力するデータ項目について更なる検討を行う必要がある。

表 2 各部屋の予測誤差

部屋	A	B	C	D	E	F
深層学習	0.160	0.160	0.133	0.202	0.204	0.147
予測 0	0.203	0.241	0.176	0.233	0.364	0.162

3.2 許容範囲内達成率の評価

予測の精度について、誤差の許容範囲を設定し、許容範囲を超える割合を評価した。空調設定が 0.5°C 単位で変更することを考慮し、予測誤差が 0.5°C を超える場合には許容範囲を超えたと判断し、それ以外であれば許容範囲内と判定した。この基準により、モデルが実際の空調設定を適切に制御するための予測ができていないかを評価する。また、空調が作動している場合とそうでない場合では、室内温度の変化予測の難易度が異なると考えられる。特に、空調が作動している期間は、部屋が積極的に利用されている状態であることが多く、人間の活動 (出入り、窓の開け閉め等) が増える。これらの要素が部屋の温度に大きな影響を与える可能性を考慮し、空調の状態を表す発停 STS の値 (空調




図 2 部屋 E のある 1 日の予測結果

の停止 (0) / 運転 (1)) に応じてそれぞれの状況における許容範囲内達成率も算出した。結果を表 3 及び 4 に示す。

全体的な誤差許容達成率を見ると、深層学習モデルは、MAE による評価とは異なり、予測 0 モデルに比べて一部の部屋で性能が下回る結果となった。特に、部屋 F の STS1 では予測 0 モデルが大幅に上回っている。これは深層学習モデルが各部屋の環境的な差異や時間的な変動を学習し、これらの影響を反映した予測が可能である一方で、部屋によっては過学習の傾向があることが考えられる。そのため、過学習を防ぐための正則化技術の導入など、モデルの改良や設定の最適化につなげていく必要がある。

表 3 深層学習モデルの許容範囲内達成率 (%)

部屋	A	B	C	D	E	F
正答率	93.9	93.6	96.6	91.4	90.3	94.0
STS 0	98.3	97.6	96.3	92.7	96.1	97.6
STS 1	86.2	86.4	97.0	69.6	84.9	87.9

表 4 予測 0 モデルの許容範囲内達成率 (%)

部屋	A	B	C	D	E	F
正答率	95.3	93.0	96.3	93.7	87.3	96.9
STS 0	98.8	97.5	99.2	95.0	94.4	98.6
STS 1	89.4	84.8	91.7	72.5	80.6	94.1

4. おわりに

本研究では、オフィスビルの空調制御に向けて、空調関連データから 1 時間後の室内温度を予測する深層学習モデルを作成し、その予測性能を評価した。ルールベースモデルと比較して一部の部屋では許容範囲内達成率が下回る結果となったが、予測誤差に関しては全ての部屋でルールベースモデルを上回る性能を示し、深層学習モデルの有用性が確認できた。

参考文献

- [1] Azuatalam, Donald, et al. "Reinforcement learning for whole-building HVAC control and demand response." *Energy and AI* 2 (2020): 100020.
- [2] Du, Yan, et al. "Intelligent multi-zone residential HVAC control strategy based on deep reinforcement learning." *Applied Energy* 281 (2021): 116117.
- [3] 宮田大輔, et al. "深層学習による室内温度予測と省エネルギー運用への適用 (第 1 報) 室内温度予測を使用した空調機制御の可能性検討." 空気調和・衛生工学会大会 学術講演論文集 令和 2 年度大会 (オンライン) 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, 2020.
- [4] 中西啓太, et al. "空調データを用いた深層学習による室温変化予測." 精密工学会学術講演会講演論文集 2020 年度精密工学会春季大会. 公益社団法人 精密工学会, 2020.