

# 機械学習・深層学習を活用した建物冷暖房負荷予測モデルの 精度に関する研究

## Study on the Accuracy of Building Cooling and Heating Load Prediction Models using Machine Learning and Deep Learning

環境・エネルギー技術部 池原 基博 MOTOHIRO IKEHARA  
 環境・エネルギー技術部 西尾 新一 SHINICHI NISHIO  
 環境・エネルギー技術部 丸山 信一郎 SHINICHIROU MARUYAMA

機械学習および深層学習は、計算パフォーマンスの向上に伴い、建設業界においても一般的になりつつある。建物の冷暖房負荷予測は、これらの適用が可能な分野の1つであり、建物の運用段階でのエネルギー消費量の削減をもたらす。本研究では、機械学習および深層学習モデルによって冷暖房負荷を予測し、複数のモデルの精度を比較検証した。その結果、「決定木による勾配ブースティング法（GBDT）」を使用したモデルの精度が最も高いという結果となった。また、予測精度を向上するために新たに追加すべきデータを検討したところ、将来の気象情報であることを示した。

**キーワード**：冷暖房負荷予測，機械学習，深層学習，勾配ブースティング法

Machine Learning and Deep Learning (ML/DL) are becoming common among the architectural, engineering, and construction industry in accordance with the improvement of computational calculation performance. Building cooling/heating load prediction is one of the applicable fields for ML/DL which brings the reduction of energy consumption in the building operation phase. The purpose of this study is to predict cooling/heating load by applying ML/DL models, and to verify the accuracy of multiple models. The results showed that the Gradient Boosting Decision Tree model has high accuracy and future weather information effects the results.

**Key Words**: Building cooling/heating load prediction, Machine learning, Deep learning, Gradient boosting decision tree model

### 1. はじめに

近年、計算機性能の向上に伴い、非線形現象の予測が可能で汎用性の高い機械学習や深層学習に注目が集まっている。建築・建設業界においても、様々な分野・場面での活用が試みられており、その一つに建物の冷暖房負荷予測<sup>1)~4)</sup>が挙げられる。建物の熱的な挙動を予測することで、空調・熱源機器の運転最適化や自動運転が可能となり、建物の運用段階において省エネルギー効果や省力化をもたらす可能性を秘めている。しかし、新築の建物において、機械学習や深層学習に必要な教師データを収集するためには、少なくとも数年間の運用データが必要となり、竣工直後から負荷予測を活用することが難しい。そのため、事前に予備学習としてシミュレーシ

ョンで教師データを作成し、竣工直後はその教師データをもとに負荷予測および空調制御を行い、実際の運用状況にあわせて調整していくことで、竣工直後から負荷予測を活用しつつ、設置した建物の特性に合わせた空調制御を実施することが可能になる。また、設備機器の更新への対応も可能となると考えられる。

本研究では、仮想の建物に対して熱回路網計算を行い、その解析結果を教師データとして機械学習・深層学習モデルを構築することで、建物の負荷予測を行う。複数の機械学習・深層学習モデルの精度を比較することで、建物用途に適したモデルの選定を行うとともに、評価指標や適切な入力変数の抽出することを目的とする。

表-1 建物条件

建築面積	約1,500 m <sup>2</sup>
延床面積	約3,000 m <sup>2</sup>
所在地	千葉県
階数	2階
窓面積率	20%
建物用途	オフィス




図-1 解析モデル

表-2 熱回路網計算条件

解析期間	1/1~12/31 (準備解析1ヶ月)	
気象データ	拡張アメダス標準年気象データ (2010年版・我孫子)	
解析ソフトウェア	EnergyPlus	
運用スケジュール	ASHRAE 90.1 2016 オフィス用途に準拠	
内部負荷	ASHRAE 90.1 2016 オフィス用途に準拠	
外皮性能	外壁・屋根・床	U値：0.5 W/m <sup>2</sup> ・K
	窓・トップライト	U値：2.4 W/m <sup>2</sup> ・K SC値：0.55

2. 年間冷房負荷データの作成

(1) 建物条件

本研究に用いる仮想建物として、表-1 の解析条件で、図-1 に示すモデルを設定した。

(2) 教師データと検証データの設定

表-2 に示す条件で熱回路網計算を行い、年間冷房負荷データを4年分(4パターン)作成した。解析エンジンはEnergyPlus(米国エネルギー省)を使用した。空調熱源システムに左右されない建物の純粋な熱負荷を算出し、夏期の冷房負荷を予測対象とした。外気温度・外気相対湿度・外部風速・日射量は拡張アメダス標準年気象データ(2010年版・我孫子)を使用し、内部負荷(在籍人員数・照明負荷・OA機器負荷)は規定の範囲内(建物の実態に整合する範囲)でランダムな値を取るよう設定した。

4パターンの冷房負荷の計算結果を図-2に示す。建物全体の冷房負荷の最大値はいずれのパターンでも約200kWとなっており、年間の負荷の推移も概ね同様の

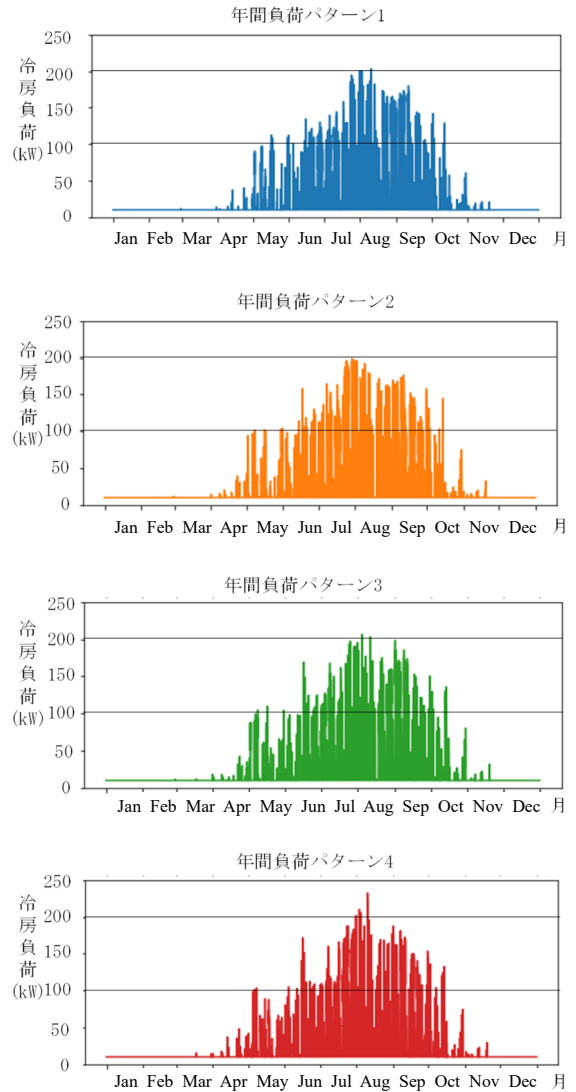


図-2 冷房負荷推移

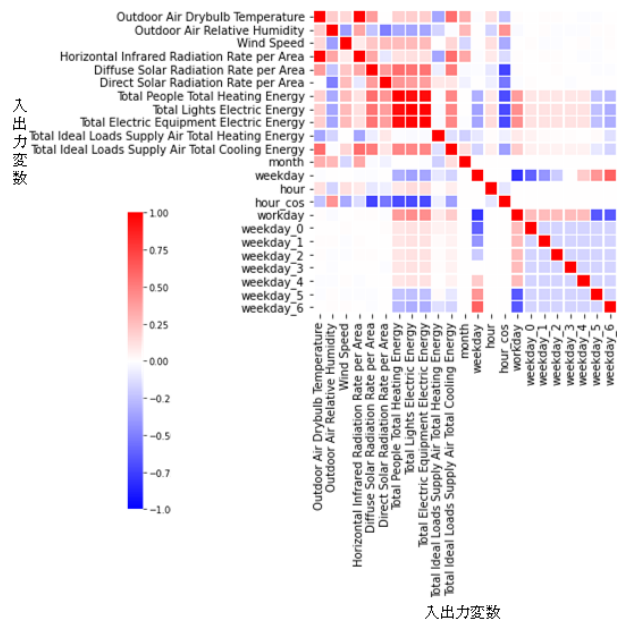


図-3 入出力変数の相関関係

傾向が確認された。

(3) 入出力変数の相関関係

熱回路網計算の入出力変数のうち、外気温度・外気相対湿度・外部風速・日射量・在籍人員数・照明負荷・OA 機器負荷・月・日・時刻・曜日は入力変数であり、冷房負荷は出力変数である。それぞれの入出力変数とそれ以外の入出力変数との相関関係を図-3 に示す。冷房負荷は外気温度、日射量、在籍人数、照明負荷、OA 機器負荷との相関が大きい結果となった。

3. 学習手法の比較

(1) 学習手法の比較概要

下記の a) ~c) に示す異なる 3 種類の学習モデルによって 24 時間後の冷房負荷の予測を行い、それぞれの精度の比較を行った。いずれのモデルでも熱負荷計算で得られた 4 年分の年間冷房負荷データのうち、3 年分を教師データに、残りの 1 年分を「実際の負荷データ」とみなし、検証に用いた。精度の評価には、「実際の 24 時間後の負荷の値」と「24 時間後の負荷の予測値」から算出した平均絶対誤差 (MAE) を用いた。MAE は式(1)によって算出した。

$$MAE = \frac{1}{N} \sum |y_{ia} - y_{ip}| \quad (1)$$

- MAE : 平均絶対誤差 (kW)
- N : サンプル数
- $y_{ia}$  : i 番目のサンプルの実際の値
- $y_{ip}$  : i 番目のサンプルの予測値

a) 決定木による勾配ブースティング法 (GBDT)

機械学習モデルとして、「決定木による勾配ブースティング法 (GBDT)」を使用した予測を行った。ハイパーパラメータの設定は表-3 の通り行った。プログラミング言語 Python3.8 と機械学習ライブラリである LightGBM を用いてモデルの構築と訓練を行った。

b) 3 層ニューラルネットワーク (3NN)

深層学習モデルの一つとして、「3 層ニューラルネットワーク (3NN)」を使用した予測を行った。深層学習ライブラリである PyTorch を用いて、表-4 のハイパーパラメータ設定を元にモデルの構築と訓練を行った。

c) 再帰型ニューラルネットワーク (RNN)

深層学習モデルの一つとして、時系列データの予測に適した「再帰型ニューラルネットワーク (RNN)」を使用した予測を行った。3NN と同様に、PyTorch を用い

表-3 ハイパーパラメータ設定 (GBDT)

学習手法	GBDT
目的関数	RMSE
学習率	0.015
最小サンプル数	20
枝分岐数	1000
L1正則化	0.5
L2正則化	0.8

表-4 ハイパーパラメータ設定 (3NN)

層数	3層
ニューロン数	27, 300, 300, 1
評価指標 (損失関数)	MAE (L1)
最適化手法	AdamW
学習率	0.001
エポック数	10,000

表-5 ハイパーパラメータ設定 (RNN)

層数	3層
ニューロン数	27, 20, 20, 1
評価指標 (損失関数)	MSE
最適化手法	Adam
学習率	0.01
エポック数	1,500


て、表-5 のハイパーパラメータ設定を元にモデルの構築と訓練を行った。

(2) 負荷予測結果

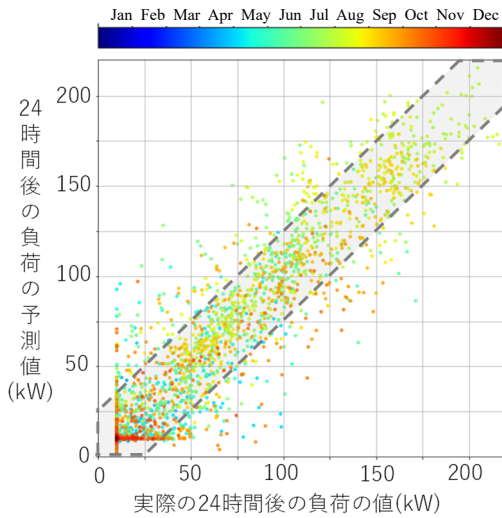
a) 各モデルによる負荷予測結果

各モデルによる冷房負荷の予測結果を図-4 に示す。図-4 の横軸は「実際の 24 時間後の負荷の値」、縦軸は「24 時間後の負荷の予測値」であり、 $y=x \pm 25$  となる領域を灰色の点線で囲って示した。また、負荷が発生した月ごとに色を変えて表示している。予測結果が  $y=x \pm 25$  の領域に含まれる割合はそれぞれ GBDT が 97.7%、RNN が 96.5%、3NN が 94.7% となっており、GBDT による予測精度が最も良いという結果となった。いずれのモデルでも、負荷が大きい時間帯での予測精度は比較的高く、負荷が小さい時間帯の予測精度が低下することが明らかとなった。

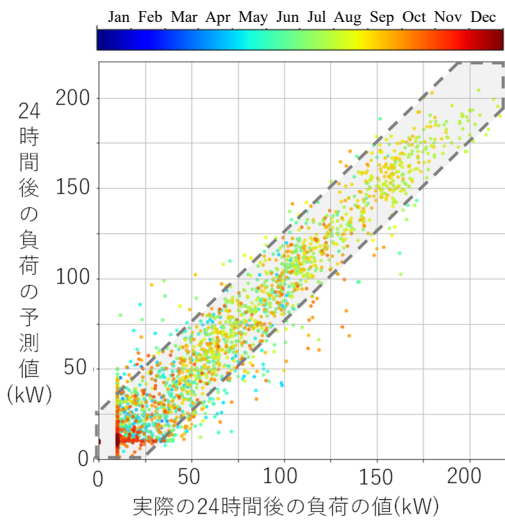
図-5 に月ごとに MAE を平均した値で各モデルを比較した結果を示す。負荷が小さい冬期を除き、いずれの月でも GBDT による予測結果の MAE が最も小さくなっている。図-6 に月ごとに平均絶対誤差率 (MAPE) を平均した値で各モデルを比較した結果を示す。MAPE は式



(1) 決定木による勾配ブースティング法 (GBDT)



(2) 3層ニューラルネットワーク (3NN)



(3) 再帰型ニューラルネットワーク (RNN)

図-4 3種類のモデルによる予測結果の比較




図-5 月別 MAE の比較




図-6 月別 MAPE の比較

(2)によって算出した。

$$MAPE = \frac{1}{N} \sum \frac{|y_{ia} - y_{ip}|}{y_{ia}} \times 100 \quad (2)$$

MAPE : 平均絶対誤差率 (%)

N : サンプル数

$y_{ia}$  : i 番目のサンプルの実際の値

$y_{ip}$  : i 番目のサンプルの予測値

MAPE の場合も MAE と同様に、GBDT による予測結果が最も精度よく評価されていることが示された。一方で、5月、6月、10月(中間期)の MAPE は他の月と比較して大きく、冷房負荷の絶対値が比較的小さい時期の精度に改善の余地を残す。

表-6 に 3 種類のモデルの解析結果のまとめを示す。基準値 MAE (kW)、基準値 MAPE (%) は、それぞれ負荷予測を行わなかった場合の年間の MAE、MAPE とし、予測を行わなかった場合には「24 時間後の負荷の予測値」が「現在の負荷」と同じ値になるとして、「実際の 24 時間後の負荷の値」と「現在の負荷の値」を用いて求めた。予測値 MAE (kW)、予測値 MAPE (%) は、3 種類それぞれの学習モデルで負荷予測を実施した場合の年間の MAE、MAPE とし、「実際の 24 時間後の

表-6 3種類のモデルの解析結果まとめ

	GBDT	3NN	RNN
基準値MAE (kW)	4.334		
予測値MAE (kW)	2.790	4.000	3.515
予測値MAE/基準値MAE (-)	0.644	0.923	0.811
基準値MAPE (%)	13.940		
予測値MAPE (%)	10.506	11.432	14.472
予測値MAPE/基準値MAPE (-)	0.754	0.820	1.038

表-8 教師データの抽出方法による精度比較

	年度ごと	無作為
基準値MAE (kW)	4.334	4.303
予測値MAE (kW)	2.792	2.868
予測値MAE/基準値MAE (-)	0.644	0.667
基準値MAPE (%)	13.940	14.026
予測値MAPE (%)	10.502	10.522
予測値MAPE/基準値MAPE (-)	0.753	0.750

表-7 評価指標による精度比較(GBDT)

	MAE	MAPE
基準値MAE (kW)	4.334	
予測値MAE (kW)	2.790	2.792
予測値MAE/基準値MAE (-)	0.644	0.644
基準値MAPE (%)	13.940	
予測値MAPE (%)	10.506	10.502
予測値MAPE/基準値MAPE (-)	0.754	0.753

表-9 予測時間による精度の比較結果

予測時間	24時間	12時間
基準値MAE (kW)	4.303	4.331
予測値MAE (kW)	2.868	2.876
予測値MAE/基準値MAE (-)	0.667	0.664
基準値MAPE (%)	14.026	14.061
予測値MAPE (%)	10.522	11.316
予測値MAPE/基準値MAPE (-)	0.750	0.805

負荷の値」と「24時間後の負荷の予測値」から算出した。MAE, MAPE のどちらで評価した場合でも, GBDT の予測値が最も小さくなっており, 3NN, RNN と比較して予測結果が精度よく評価されていることが示された。

#### b) 学習の際の評価指標による予測精度

表-7 に予測モデルを GBDT とし, モデルの学習の際の評価指標を MAE, MAPE とした場合の予測結果の比較を示す。学習の際の評価指標による予測値の差異は見られなかった。

#### c) 教師データの抽出方法による予測精度

表-8 に教師データの抽出方法を変えた場合の予測結果を示す。これまでの教師データの抽出方法, すなわち4年分の年間冷房負荷データから, 3年分の教師データを抽出する際に, 1年間の連続する負荷データを3つ抽出する方法を「年度ごと」と表記する。別の抽出方法では, 時刻ごとに無作為に「3年の教師データ」と「1年分の実際の負荷データ」に分けた。この抽出方法を「無作為」と表記する。予測モデルを GBDT とし, モデルの学習の際の評価指標は MAPE を用いた。基準 MAPE に対する予測 MAPE が小さいのは教師データを「無作為」に抽出する方法であり, 「無作為」に抽出する方が予測精度が高いという結果となった。

#### d) 予測時間による予測精度

表-9 に, 「12時間後の冷房負荷」の予測モデルと「24時間後の冷房負荷」の予測モデルと精度の比較を行った結果を示す。学習モデルは GBDT, 評価指標は MAPE を

用い, 教師データの抽出方法は「無作為」に抽出する方法とした。「12時間後の冷房負荷」の予測モデルでは, 「24時間後の冷房負荷」の予測モデルと比較して12時間後と近い未来の冷房負荷を予測しているにも関わらず, 予測モデルの精度の向上は見られない。これは, 例えば, 午前10時と午後10時のオフィスでは, 内部負荷や気象条件が大きく異なるように, 「12時間後の冷房負荷」の予測モデルでは「24時間後の冷房負荷」の予測モデルよりも, 建物の使用状況が大きく異なるためと考えられる。

## 4. 入力変数の追加検討

### (1) 入力変数の再設定

中間期の予測精度をさらに向上させるため, 入力変数の追加検討を行った。気象予報により翌日の気象データが入手できるという想定のもと, 24時間後の外気温度・日射量を入力変数として追加し, GBDT による予測を行った。なお, 気象予報の精度は考慮せず, 入力変数に追加した値は24時間後の実際の値とした。

### (2) 入力変数追加による予測結果

図-7 に入力変数追加前, 図-8 に追加後の予測結果を示す。入力変数追加前は5月, 6月, 10月の MAPE が15%を超えていたのに対し, 追加後はいずれの月も15%を下回る結果となった。中間期は日によって外気温度条




図-7 月別 MAE・MAPE の比較 (入力変数追加前)

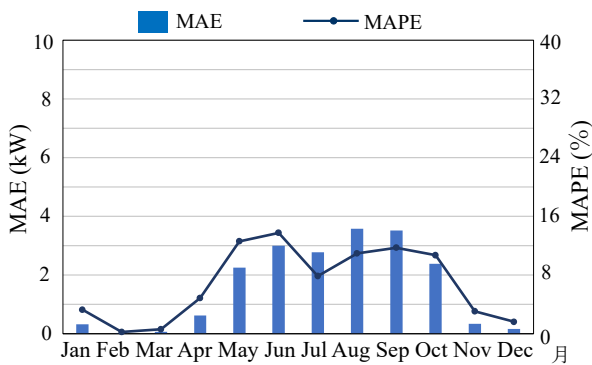


図-8 月別 MAE・MAPE の比較 (入力変数追加後)

件が特に変化しやすく、それらが負荷に与える影響も大きいいため、冷房負荷を予測する時刻の気象条件が入力変数として加わることで、精度が大きく向上したと考えられる。

## 5. まとめ

本研究では、熱回路網計算によるシミュレーション結果を教師データとして、建物の冷房負荷予測を行う機械学習・深層学習モデルを構築した。結果を以下に示す。

- ①「決定木による勾配ブースティング法 (GBDT)」, 「3層ニューラルネットワーク (3NN)」, および「再帰型ニューラルネットワーク (RNN)」の各モデルで予測を行った結果、GBDTによる予測モデルが最も高い精度を示した。
- ②教師データの抽出方法として、「年度ごと」にデータを抽出するよりも「無作為」に抽出する方が予測精度が高いという結果となった。
- ③建物の使用状況が異なることから、「24時間後の冷房負荷」の予測モデルと比較して「12時間後」と近い未来の冷房負荷を予測しているにも関わらず、予測モデルの精度の向上は見られなかった。

- ④予測時刻の気象データを入力変数として追加することで、中間期の予測精度が大きく向上することが示された。

本研究での冷暖房負荷予測結果の活用方法として、得られた冷暖房負荷の結果に基づいた熱源・空調運転制御システムの構築が考えられる。教師データに基づいて1つの運転制御を実行するのではなく、省エネ運転 (CO<sub>2</sub>排出量の削減) を重視する運転制御や快適性を重視した運転制御等、複数の運転制御が可能なシステムを構築することで、建物使用者の多様なニーズに応えることができるようになると思われる。

**謝辞:** 本報は、令和3年度空気調和・衛生工学会大会の投稿論文を一部加筆したものである。本研究に関し、ご助言を頂いたオーヴ・アラップ・アンド・パートナーズ・ジャパン・リミテッドの菅健太郎氏、竹中大史氏、清野新氏、二宮颯佑氏に謝意を表します。

## 参考文献

- 1) C. Deb et al., "Forecasting diurnal cooling energy load for institutional building using Artificial Neural Networks", *Energy and Buildings*, Vol.121, pp.284-297, 2016
- 2) 小柳秀光ほか: ニューラルネットワークを使用した時刻別電力・冷暖房負荷予測手法における予測精度向上を目的とした学習期間決定手法の提案と検証, 日本建築学会環境系論文集, 第79巻, 第706号, pp.1049-1059, 2014.12
- 3) 川島実ほか: 空調システム運転制御を対象とした実時間負荷予測手法に関する研究, 日本建築学会計画系論文集, 第61巻, 第484号, pp.43-51, 1996.6
- 4) 塩谷正樹ほか: 階層型3層ニューラルネットワークを用いた熱負荷予測手法の予測精度に及ぼす熱負荷特性の影響, 日本建築学会計画系論文集, 第62巻, 第502号, pp.43-50, 1997.12