

機械学習による蓄熱槽特性の予測手法の開発

研究背景と目的

近年、建物設備の最適運転にニューラルネットワーク (Artificial neural network, ANN) など計測データに基づいた統計モデルの活用が注目されている。しかし、緻密な物理モデルに対してモデル化が容易であるANNは、学習データ及び学習の方法によって予測誤差が生る懸念がある。そこで本研究では、温度成層型蓄熱槽の特性をモデル化し、出口温度及び槽内温度の予測を通じてANNの利用可能性を明らかにする。

研究手法

ANNモデル化のために必要な学習データにおいて、異なる学習データの整備による学習結果を考察する。

学習データの整備

1) 物理モデル作成を通じた計算結果の活用

- 蓄熱槽の温度成層数：20 層
- 蓄熱槽内の初期温度：14 °C
- 蓄熱槽壁面の熱貫流率：0.5 W/(m² K)
- 蓄熱時、熱源からの流入水温度 (T_C) : 4 °C
- 放熱時、二次側からの還り温度 (T_R) : 14 °C
- 熱源機の合計出力：20,500 kWと仮定
- 蓄熱量運用計画

CASCADEⅢの建物用途別平均負荷データの8月の冷房負荷を参照、2000パターンをランダムに作成

2) 実運用データの活用

- 東京都に所在する実際の建物の運用データ
- 計測期間：2016年1月1日～12月31日 (計測時間解像度10分)
- 蓄熱槽の温度成層数：20 層




図1. 蓄熱槽の物理モデルの概要




図2. 2000パターンの蓄熱槽運用計画

機械学習による蓄熱槽特性の予測手法の開発

ケーススタディ

- Q^{t-1} : 前時刻の残存熱量
- Q^t : 現在時刻の予定残存熱量
- T_{20}^{t-1} : 前時刻の最下層温度
- T_{20}^t : 現在時刻終了時の最下層温度
- $T_1^{t-1}, \dots, T_{20}^{t-1}$: 前時刻の全離散層別温度
- $T_1^t, \dots, T_{20}^t$: 現在時刻終了時の全離散層別温度

表 1. ケーススタディの条件

	学習データ	入力データ	出力データ
Case 1	物理モデル	$Q^{t-1}, Q^t, T_{20}^{t-1}$	T_{20}^t
Case 2-1	実運用データ	$Q^{t-1}, Q^t, T_{20}^{t-1}$	T_{20}^t
Case 2-2	実運用データ	$Q^{t-1}, T_1^{t-1}, \dots, T_{20}^{t-1}$	$T_1^t, \dots, T_{20}^t$

学習設定


- 使用Tool : MATLAB R2017a Neural network toolbox
- 使用アルゴリズム : Levenberg-Marquardt

表 2. ケース別の学習設定条件


	ANNの構造	隠れ層の ノード数
Case 1	4層 (入力層 - 隠れ層 - 隠れ層 - 出力層)	10ノード
Case 2-1	4層 (入力層 - 隠れ層 - 隠れ層 - 出力層)	10ノード
Case 2-2	4層 (入力層 - 隠れ層 - 隠れ層 - 出力層)	20ノード

学習結果


Case 1



Case 2-1



Case 2-2



➡ 学習結果、3ケースとも高い予測精度を見せた。そこで、学習データ整備の難易度に応じた適切なANN構造や入力及び出力データを選ぶことが重要なのが分かった。