

機械学習を活用した熱源・空調システムのモデリング手法に関する研究

(第1報) インバータターボ冷凍機のモデル化検討

尾 形 甫 (新菱冷熱工業)
矢 島 和 樹 (新菱冷熱工業)

福 井 雅 英 (新菱冷熱工業)
金 子 友 昭 (新菱冷熱工業)

本稿では、機械学習を用いたインバータターボ冷凍機のモデル化手法について述べる。近年、ディープラーニングや機械学習は急速に進歩しており、設備分野においてもその活用方法が模索されている。機械学習は、質が高く十分な量のデータを学習することで、ポテンシャルを発揮すると一般的に言われるが、設備分野における代表的なデータであるBEMSデータは、一概に条件を満たすとは限らない。検討の対象は、インバータターボ冷凍機の消費電力を求めるモデルとし、ニューラルネットで作成した。データの質と量が異なる8つの学習データセットを用い、2種類のモデルのテストを行った。その結果、シミュレーションソフトで作成したデータによりモデルを事前に訓練し、その後BEMSデータを学習しモデルをチューニングする手法では、学習データセットの違いが消費電力の予測性能に与える影響はわずかであった。一方で、BEMSデータのみでモデルを訓練した場合は、学習データセットの違いが消費電力の予測性能に与える影響は大きいことを示した。あらかじめ、シミュレーションによるデータ等を用い、機械の特性を広くモデルに学習させることが有効であると示唆された。

はじめに

セントラル空調システムには、一般的に中央監視設備が附帯しており、日々の運転データが蓄積されている。これらの運転データは、コミッショニングやシミュレーションなどに活用されてきた。近年では深層学習や機械学習に関する技術の進歩から、さらなるデータ活用の方法として、熱源最適制御¹⁾への適応や不具合の検知²⁾について研究が進められている。

一般に深層学習や機械学習は、質が高く十分な量のデータを学習することで、ポテンシャルを発揮すると言われる³⁾。しかし、中央監視に蓄積されたデータは、必ずしもこの条件を満たさない。例えば、熱源・空調システムの運転データが持つ特徴を考えると、データの偏りが挙げられる。まず冷凍機の冷却水流量に着目すると、定流量制御か冷凍機の出入口温度差を一定とした変流量制御が一般的である。定流量制御では一定の値、変流量制御では限られた負荷率と流量組合せしか存在しない。次に冷凍機の負荷率に着目すると、プラントの運転思想に則り、冷凍機種ごとに一定の負荷率帯で運用されることが多い。さらに機種によっては、夏季のピーク時間に限るなど、わずかな時間しか運転しない。運転時間が短

いということは、データの蓄積が少ないことを意味する。このような状況を踏まえると、一概に高品質で十分な量のデータを提供できるとは限らない。このような背景から、本研究は、データの特徴に影響されないモデリング方法を明らかにすることを目的とする。

1. 検討対象

1.1. 冷凍機種

本報では、インバータターボ冷凍機を対象とした。表-1に機器仕様を示す。インバータターボ冷凍機は、部分負荷特性が優れていることから、低負荷から高負荷まで幅広い負荷率帯で使用されるケースが多い。また高効率であることから、年間を通して運転されているケースが多く、運転データが豊富に蓄積されている。さらに冷却水の制御は、部分負荷運転の頻度が多いことから変流量、外気温の低い時期の運転頻度が多いことから変温度であるケースが多い。これらより、冷凍機に関する要素を網羅的に検討するのに適している機種であると判断した。

1.2. データ

Aプラントにおける32ヵ月分の運転データを用いた。データの種類はアナログで、1時間の平均値である。データの分布を図-1に示す。冷却水入口温度は、定格の32℃からメーカーが下限温度と指定する12℃まで分布している。特に12℃から14℃のデータが多い。負荷率は5%未満から95%超まで広く存在するが、インバータターボ冷凍機の特徴である部分負荷運転のデータが多い。冷却水流量は、45%から100%まで分布している。65%から95%までのデータ数は少ない。なお、対象機の下限流量である50%を下回るデータが確認できるが、これは50%に制御した際のわずかな下振れをカウントしたものと推察される。冷水出口温度は、6.0℃から6.4℃の間にほぼ全てのデータが存在している。これらのデータから、機械が停止中のデータを全て、機械が起動および停止した時刻のデータを1時間分除去し、検討用のデータに用いた。

2. モデルの作成

モデルは、ニューラルネットワーク（以下、NNモデルとする）とファインチューニング機能を設けたニューラルネットワーク（以下、FTモデルとする）の2種類を作成した。

2.1. NNモデル

説明変数は冷水出口温度、冷水流量、冷却水入口温度、冷却水流量、冷水出入口温度差の5変数とした。目的変数は、主電動機の電力とした。隠れ層の数とニューロンの数は、グリッドサーチにより決定した。

2.2. FTモデル

ファインチューニングとは、新たに設定した課題に適応させるため、別課題のデータを十分に学習したモデルに対し、新たな課題のデータを再学習させることでモデルを微調整する手法である。ファインチューニングの概念を図-2に示す。学習データの量や質を確保できない課題に対し、有効な手法である。本研究では、事前学習に一般的なインバータターボ冷凍機の実運転データを用いる。事前の学習に使用する一般的な特性値は、メーカーの提供値およびLCЕМ ツールを用いて作成した。なお、冷水流量および冷却水流量は、冷凍機の容量により使用レンジが異なるが、USRTあたりの流量に換算することで対応した。説明変数および目的変数は2.1節と同様で、学習手順は以下の通りである。

- 1) 一般的な機器特性を学習させる。
- 2) 一層目の重みとバイアスを固定する。

- 3) 実際のデータセットを学習させる。このとき入力に近い層ほど学習率（重みとバイアスの調整率）を小さく設定する。

表-1 機器仕様

項目	定格値
冷凍能力	900 USRT (11.4 GJ)
冷水出入口温度	12.0℃ → 6.0℃
冷水流量	453.6 m³/h
冷却水出入口温度	32.0℃ → 37.0℃
冷却水流量	635.5 m³/h
主電動機消費電力	499.0 kW
定格 COP	6.3




図-1 データの分布




図-2 ファインチューニングの概念

2.3. モデルの精度

データのうち、24 ヶ月分を学習（以降、データセット A とする）、8 ヶ月分をテストに使用した。データの内訳を表-2 に示す。式 (1) により、各モデルによるテストの二乗平均平方根誤差（Root Mean Squared Error：以下、RMSE とする）を算出した。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (y_i - \hat{y}_i)^2} \quad \cdots \cdots (1)$$

y_i : 実際の電力 [kW]
 $\hat{y}_i$: 予測した電力 [kW]
 n : データ数 [-]

テストの RMSE は、NN モデルが 9.0 kW、FT モデルが 7.2kW であり、FT モデルが NN モデルの精度を上回った。次に、定性的な評価のため、学習後のモデルに部分負荷特性を推論させた結果を図-3 に示す。負荷率 75 % 超では、NN モデルと FT モデルともに冷却水温度の高低、冷却水流量の多少と COP の関係⁴⁾が再現できている。また両モデルの傾向に特段差異は見られない。一方、50 %以下では、NN モデルの部分負荷特性は、冷却水流量 50 %の COP（破線）が、冷却水流量 100 %（実線）の COP と同程度以上になっており、機器特性を再現できていないことがわかる。よって、定量的かつ定性的に FT モデルが NN モデルを上回っている。

3. 学習データの特徴が推論に与える影響の検討

はじめに述べたように、運転データには偏りが存在する。しかしデータセット A は、点数の多寡はあるものの、データが幅広く存在するデータセットである。そこで意図的に特徴を持った学習データセットを作成し、学習データの特徴が推論にどのような影響を与えるか検討した。

3.1. 比較用の学習データセット

表-3 に学習データセットの内訳を示す。データセット A から、想定した特徴に基づきデータを削除した。データセット B は、データの不足を想定しデータセット A のデータを満遍なく削除した。データセット C とデータセット D は、冷却水流量の偏りを想定し、それぞれ冷却水流量の多いデータと少ないデータを削除した。データセット E とデータセット F は、冷却水温度の偏りを想定し、それぞれ冷却水温度の高いデータと低いデータを削除した。データセット G とデータセット H は、冷凍機負荷率の偏りを想定し、それぞれ負荷率の高いデータと低いデータを削除した。

表-2 データセットの内訳

	学習データ (データセット A)	テストデータ
データ期間	24 ヶ月	8 ヶ月
データ点数	17,255	5,675
負荷率範囲	0 ～ 100 %	0 ～ 100 %
冷却水流量範囲	0 ～ 100 %	0 ～ 100 %
冷却水温度範囲	12 ～ 32 °C	12 ～ 32 °C




図-3 部分負荷特性の推論

3.2. 結果と考察

表-4 に推論精度の比較を示す。テストに用いたデータは、2.3 節と同様である。RMSE は、データセット D を除き、全て FT モデルが上回った。図-4 に部分負荷特性の比較を示す。データセット B は、データセット A と同様の傾向であった。データセット C の NN モデルは、データセット A と比較して冷却水量 100 %が大きく変化しており、学習データを削除した範囲と一致する。学習したデータの範囲が、推論可能な範囲に影響していると推察される。データセット D、E、F および G の NN モデルは、冷却水温度 12 °C の低負荷率帯で冷却水流量 100 %と 50 %の COP が逆転しており、冷却水流量と COP の相関が再現できていない。さらにデータセット D、E および G では、負荷率が下がるほど COP が向上する特性になっており、負荷率と COP の相関も再現できていない。データセット H の NN モデルは、冷却水量と COP の相関は捉えられているが、負荷率が小さい条件で COP が下がっておらず、負荷率と COP の相関が再現できていない。一方、FT モデルは、全てのケースで冷却水温度、冷却水流量、負荷率と COP がインバーターボ冷凍機特有の相関を示しており、学習データの不足や偏りの影響が少なかった。データセット D の NN モデルは、RMSE で FT モデルを上回っているが、機器特性は再現できていない。よって定量的な指標だけでは、モデルの優劣を判断できないと考えられる。

表-3 学習データセットの内訳

	データ セット B	データ セット C	データ セット D	データ セット E	データ セット F	データ セット G	データ セット H
データ期間	24 ヶ月分	24 ヶ月分	24 ヶ月分	24 ヶ月分	24 ヶ月分	24 ヶ月分	24 ヶ月分
データ点数	863	15,857	4,870	16,715	10,124	15,791	11,133
負荷率範囲 [%]	0 ~ 100	0 ~ 100	0 ~ 100	0 ~ 100	0 ~ 100	0 ~ 80	30 ~ 100
冷却水流量範囲 [%]	50 ~ 100	50 ~ 90	60 ~ 100	50 ~ 100	50 ~ 100	50 ~ 100	50 ~ 100
冷却水温度範囲 [°C]	12 ~ 32	12 ~ 32	12 ~ 32	12 ~ 28	16 ~ 32	12 ~ 32	12 ~ 32

表-4 推論精度の比較

	データ セット B		データ セット C		データ セット D		データ セット E		データ セット F		データ セット G		データ セット H	
モデルの種類	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT
RMSE [kW]	8.6	8.1	8.2	7.2	9.7	9.9	10.3	7.7	9.0	8.7	8.7	6.0	10.4	8.5




図-4 部分負荷特性の比較

4. まとめ

本報では、機械学習を用いたインバーターボ冷凍機のモデル化手法について検討し、以下の知見を得た。

- 1) 定量的な指標だけでは、モデルの優劣を判断できない。
- 2) 運転データのみでモデルを訓練すると、学習データの量や偏りにより機器特性の再現が変化する。
- 3) ファインチューニングの活用で、定量的かつ定性的に優れた推論結果が得られた。

今後は、冷却塔やポンプなど、その他の熱源機器について検討を進める。

参 考 文 献

- 1) 矢崎, 他 (2020-2022). 都市型地域冷暖房の省エネルギー手法に関する研究 (その 3～その 5). 空気調和・衛生工学会大会学術講演論文集.
- 2) 宮田, 他 (2018-2022). 機械学習を用いた空調熱源システムの不具合検知・診断 (第 1 報～第 3 報). 空気調和・衛生工学会論文集.
- 3) 有賀, 他 (2018). 仕事で始める機械学習. オライリー・ジャパン. pp.97-105
- 4) 和島, 他 (2008). 期間効率を最大化する新型ターボ冷凍機. 三菱重工技報 VOL.45 No.2. pp.35-39

謝 辞

本研究を進めるにあたり、丸の内熱供給株式会社に運転データをご提供いただいた。ここに謝意を表する。