

# 冷凍機のモデリング方法に関する考察

## Considerations on Modeling Method for Refrigeration Machine

尾形 甫 (新菱冷熱工業)

福井 雅英 (新菱冷熱工業)

矢島 和樹 (新菱冷熱工業)

金子 友昭 (新菱冷熱工業)

### 1. はじめに

日本は、2050年カーボンニュートラルの実現を公約に掲げており、温室効果ガスの排出抑制に関する施策が進められている。国・地方脱炭素実現会議では、業務用ビルにおける省エネルギーを重点対策項目<sup>1)</sup>として定めている。熱源・空調システムの省エネルギーを図る技術として、最適制御が挙げられ、研究や開発、社会実装が進んでいる<sup>2)</sup>。近年は、新たな試みとして、機械学習や深層学習を活用した事例も散見される<sup>4)</sup>。一般に、機械学習や深層学習の推論精度を高めるには、良質で大量の学習データが必要とされる。特に熱源設備は、運転管理に管理者の思想が色濃く反映され、負荷に対する運転機種を選択や使用する流量帯および温度帯などがパターン化する傾向にあり、一概に高品質で十分な量の学習データを提供できるとは限らない。そこで本報では、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し、8種類の学習データセットと2種類のモデルを用意し、学習データおよびモデルの違いが、推論値に与える影響について解析した。

### 2. 対象機種

対象機は、Aプラントで稼働している900USRTのインバータターボ冷凍機である。冷水の定格値は、入口温度が12.0℃、出口温度が6.0℃、流量が453.6m<sup>3</sup>/hである。冷却水の定格値は、入口温度が32.0℃、出口温度が37.0℃、流量が635.5m<sup>3</sup>/hである。主電動機の定格消費

電力は499.0kWで、COPは6.3である。

### 3. データ概要

#### 1) データの全体像

中央監視で収集した32ヵ月分のデータのうち、24ヵ月分を学習に、8ヵ月分をテストに用いた。データの種類はアナログで1時間平均値である。機械学習の妨げとなるため、冷凍機が停止中のデータ全てと、冷凍機が起動したタイミングおよび停止したタイミングを含むデータを除外した。

#### 2) 学習データセット

学習データセットの一覧をTable 1に示す。データセットAは、比較の基準であり、全てのデータである。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から満遍なくデータを削除した。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た条件である。データセットAから、冷却水流量の上限近傍(データセットC)と下限近傍(データセットD)のデータをそれぞれ削除した。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た条件である。データセットAから、冷却水温度の上限近傍(データセットE)と下限近傍(データセットF)のデータをそれぞれ削除した。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た条件である。負荷率の上限近傍(データセットG)と下限近傍(データセットH)のデータをそれぞれ削除した。

Table 1 List of training datasets

データセット	A	B	C	D	E	F	G	H
データ点数	17,225	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	0~100	0~80	30~100
冷却水流量範囲[%]	50~100	50~100	50~90	60~100	50~100	50~100	50~100	50~100
冷却水温度範囲[℃]	12~32	12~32	12~32	12~32	12~28	16~32	12~32	12~32

### 3) 解析データセット

生成したモデルの感度を網羅的に確認するため、説明変数を離散的に設定した解析データセットを作成した。冷却水入口温度は 12.0 °C から 32.0 °C まで 2.0 °C 刻み、冷却水流量は 317.8 m<sup>3</sup>/h から 635.5 m<sup>3</sup>/h まで 63.6 m<sup>3</sup>/h 刻み、冷水出入口温度差は、6.0 K から 0.6 K まで 0.6 K 刻み（負荷率 10 % 相当）とした。なお、冷水流量は 453.6 m<sup>3</sup>/h、冷水出口温度は 6.0 °C 固定である。データの総数は 2,640 点である。

## 4. モデル概要

### 1) モデル

第一のモデルは、ニューラルネットワーク（以下、NN モデルとする）で作成した。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。

第二のモデルは、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）で作成した。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。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。本報では、一般的なインバータターボ冷凍機の特性値を事前に学習させる。その後、検討対象とする冷凍機の実運転データで再学習を行う。事前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 LCEM ツール<sup>5)</sup>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、1 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前節と同様で、学習手順は以下の通りである。

- i) 一般的な機器特性を学習させる。
- ii) 一層目の重みとバイアスを固定する。
- iii) Table 1 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を小さく設定する。

### 2) 学習結果

NN モデルおよび FT モデルに対しデータセット A~H をそれぞれ学習させた後、テストデータセットで精度を確認した。精度の指標は二乗平均平方根誤差（Root Mean Squared Error : 以下、RMSE とする）とし、式 (1) により算出した。

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

$y_i$  : 実際の電力 [kW]

$\hat{y}_i$  : 予測した電力 [kW]

$n$  : データ数 [-]

各学習およびテストの RMSE を Table 2 に示す。学習の RMSE は、5.3 kW から 11.6 kW、テストの RMSE は 7.2 kW から 10.4 kW であった。いずれも定格消費電力と比較して 3 % (15.0 kW) 未満であり、十分に学習が行われている。

### 5. 学習データが推論値に与える影響の解析および考察

前章でデータセット A から H を学習させた各モデルを用い、解析データセットの推論を行った。最もデータ数が多いデータセット A を学習した条件を基準とし、比較を行った。

#### 1) 推論値分布の可視化による傾向の把握

データセット A を学習した条件と D を学習した条件の比較を代表例とし、各説明変数の値に対する消費電力予測値の頻度分布図を Fig.1 に示す。色の濃淡が頻度を表し、上段が NN モデル、下段が FT モデルの結果である。NN モデルでは、データセット A を学習した結果と比較し、データセット D を学習した結果は、消費電力を低く予測する傾向にある。また、色が薄く頻度の少ない欄が増加しており、バラつきが大きくなったと考えられる。一方、FT モデルでは、データセット A を学習した結果とデータセット D を学習した結果は、同様の傾向を示している。学習データの偏りや不足が推論値に与える影響は、NN モデルでは大きく、FT モデルでは小さいと考えられる。

Table 2 List of root mean square error

データセット	A		B		C		D		E		F		G		H	
モデルの種類	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT	NN	FT
学習 RMSE [kW]	6.1	8.0	6.7	8.0	5.3	6.3	9.4	11.6	6.3	7.2	7.7	9.0	5.3	5.6	7.6	9.0
テスト RMSE [kW]	9.0	7.2	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




Fig.1 Frequency distribution diagram of explanatory variables and predicted values

## 2) 正確さおよび精度の検討

データセットAを学習したモデルで推論した消費電力を基準とし、データセットBからHを学習したモデルで推論した消費電力の偏差を算出した。Fig.2にNNモデルの偏差の分布を示し、Fig.3にFTモデルの偏差の分布を示す。Table 3にモデルおよび学習データごとの偏差の分散を示す。まず、偏差の中央値は、NNモデルが5.5 kWから-8.4 kW、FTモデルが-1.0 kWから-5.5 kWであった。説明変数の範囲およびデータ点数が最も充実しているデータセットAを学習した条件の推論値が真値であると仮定すると、FTモデルはNNモデルと比較して偏差が小さいことから、正確さが優れていると示された。

つぎに、NNモデルのうち、偏差範囲が最も小さい条件は、Fを学習した条件であり、その最大値は14.2 kW、

最小値は-5.3 kWであった。一方で、偏差範囲が最も大きい条件は、Bを学習した条件であり、その最大値は38.0 kW、最小値は-55.8 kWであった。偏差の分散は、18.0 kW<sup>2</sup>から300.7 kW<sup>2</sup>であった。FTモデルのうち、偏差範囲が最も小さい条件は、Eを学習した条件であり、その最大値は2.0 kW、最小値は-11.6 kWであった。一方で、偏差範囲が最も大きい条件は、Dを学習した条件であり、その最大値は12.7 kW、最小値は-23.5 kWであった。偏差の分散は、16.1 kW<sup>2</sup>から89.8 kW<sup>2</sup>であった。データセットAを学習した条件の推論値が真値であると仮定すると、FTモデルはNNモデルと比較して偏差のバラつきが小さいことから、精度が高い。よって、ファインチューニングを活用すると、学習データの質や量が推論に与える影響を少なくできる。




Fig.2 Deviation in NN Model




Fig.3 Deviation in FT Model

Table 3 Variance of deviation for dataset A

データセット	B	C	D	E	F	G	H
NN モデル	300.7	88.7	80.7	42.3	18.0	53.3	29.3
FT モデル	39.8	89.8	43.5	16.8	31.7	16.1	26.3

## 6. まとめ

本報では、機械学習に用いる学習データの質や量が推論に与える影響を確認した。その結果、以下の知見を得た。

- ・ニューラルネットワークは、学習した説明変数の範囲や量により、推論の結果が変わる。
- ・一般的な機器特性を学習したモデルに対しファインチューニングすると、学習に含まれる説明変数の範囲や量の影響が小さくなる。

## 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。

## 参 考 文 献

- 1) 国・地域脱炭素連絡会議: 地域脱炭素ロードマップ～地方からはじまる、次の時代への移行戦略～, p.12, 2021.
- 2) 矢島和樹 他: 熱源・空調システムの最適制御技術に向けた研究 第 1 報—冷却水温度の設定値最適化と実測による効果検証, 空気調和・衛生工学会 論文集 42 巻 248 号 pp.11-19, 2017.
- 3) 福井雅英 他: 大規模オフィスでの中温冷水を利用した高効率熱源・空調システムに関する研究 (第 5 報) 熱源最適運転計画の概要, 空気調和・衛生工学会大会学術講演論文集 pp.205-208, 2015
- 4) 矢崎淳史 他: 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 3,4,5), 空気調和・衛生工学会大会学術講演論文集 (pp.77-80, pp.173-176, pp.125-128), (2020, 2021, 2022).
- 5) [https://www.mlit.go.jp/gobuild/sesaku\\_lcem\\_lcemtool\\_index.htm](https://www.mlit.go.jp/gobuild/sesaku_lcem_lcemtool_index.htm) (2024)