

地域冷暖房施設における 最適運転計画システムの実用化に関する研究

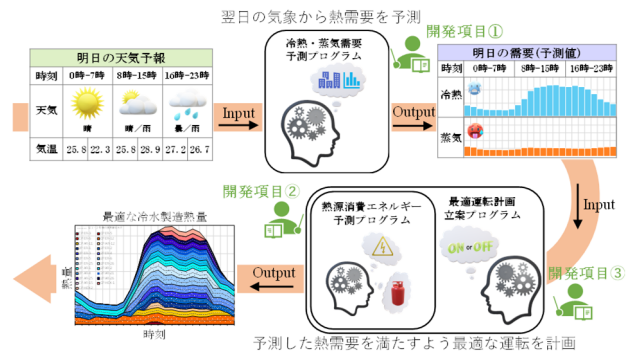
尾形 甫*¹
矢島 和 樹*¹

福井 雅 英*¹

地域熱供給施設が排出する CO₂ の抑制を目的とし、熱の需要に合わせて 24 時間あたりの CO₂ 排出量を最小とする熱源の運転計画を探索する手法について検討した。はじめに機械学習による熱需要予測モデルについて感度解析を行い、必要な説明変数と予測精度を明らかにした。つぎにプラントを構成する全ての熱源機器単体のエネルギー消費量モデルについて予測精度を確認した。さらにプラント全体を対象とした消費エネルギーの予測精度も確認した。さいごに各時刻における熱源の負荷率を設計変数とし、遺伝的アルゴリズムによる最適化を試みた。その結果、目的関数の設定に応じて、合理的な運転計画を導けることを示した。

はじめに

ネットゼロカーボンの実現には、温室効果ガスの排出量削減、吸着量および除去量の増加が求められる。そのうち熱源システムの高効率化は、温室効果ガスの排出量削減に寄与する。地域冷暖房施設（District Heating and Cooling：以下、DHC とする）は、各建物に熱源システムを設ける個別熱源方式に比べ、高効率な機器の採用や効率的な運転管理が可能で省エネルギー効果が期待でき、社会情勢に適したシステムである。一方で、DHC における熱源システムの機器構成は一般ビルと比べるとはるかに複雑なうえ、供給規程の遵守など運用上の制約が多い。さらに都市部では、契約需要家数が増加し、求められる供給量が年々増える傾向にある。あわせて熱源機器の更新や増設も頻繁に実施される。熱需要側、供給側ともに年々変化していることから、優れた運転判断が極めて難解である。そのため熱の需要に合わせて、最も高効率となる熱源機の起動時刻、停止時刻および各時刻の機器負荷率を導く最適運転計画システムの構築が求められる。最適運転計画の算出フローを図-1 に示す。最適運転計画の導出には、熱需要の予測、熱源機の消費エネルギー予測および最適化計算の 3 要素が必要である。既往研究では、山本ら¹⁾や中村ら²⁾が同様のシステムを検討している。しかし、DHC の熱需要は、需要家の建物用途や立地により異なること、熱源システムは一品受注生産であり各々



様々な特徴を有することから、要素技術や手法の有効性は定かでない。そこで本研究では、最適運転計画システムの構築を目指す実在 DHC を対象に、要素技術の感度解析および最適化手法の有効性について検討した。

1. 検討対象

1.1 熱供給地域

本施設の所在地は神奈川県横浜市で、熱供給範囲はみなとみらい中央地区一帯である。2023 年 3 月時点の供給延床面積は約 4,250,000 m²、需要家件数は 66 件である。需要家件数と販売熱量は年々増加しており、10年で約 1.3 倍となっている。今後も増加が見込まれており、熱需要の変化に追従可能な予測手法が必須である。

*¹ 新菱冷熱工業(株)

1.2 熱供給設備

図-2 に 2023 年 3 月時点の熱源系統図を示す。熱源機は、センタープラントと第 2 プラントの 2 カ所に設置されており、連携して地域へ熱供給している。供給媒体は、6.0 °C の冷水と 0.8 MPa の蒸気である。

センタープラントの冷熱源は、固定速ターボ冷凍機（以下、ER とする）が 1 台、ブライントーボ冷凍機（以下、LER とする）が 2 台、可変速ターボ冷凍機（以下、IER とする）が 1 台、蒸気吸収式冷凍機（以下、DAR とする）が 2 台、温水吸収式冷凍機（以下、SAR とする）が 1 台で、冷水製造能力は 235.9 GJ/h である。なお、LER はダブルエバポレータ式であり、非蓄熱運転時は冷水の直送が可能である。カプセル式潜熱蓄熱（STockage par chaleur Latente：以下、STL とする）が 2 槽付設しており、蓄熱容量は 379.8 GJ である。冷却塔は、合計 12 セルで 2 つの系統に分かれている。それぞれの系統は、連通管で接続されており、稼働する冷凍機と冷却塔の組み合わせにより通水する経路が変化する。冷却塔の運転台数と極数は放熱量にあわせて制御している。温熱源は、水管式ボイラ（以下、WB とする）と減温減圧装置（以下、PTU とする）が各 2 台、炉筒煙管式ボイラ（以下、SB とする）が 4 台、排ガスボイラ（以下、GB とする）が 1 台で、蒸気製造能力は 0.8 MPa 換算で 180.6 t/h である。発電装置（以下、GE とする）が 1 台設置されており、発電力は 2,000 kW である。排温水は SAR、排ガスは GB で使用している。

第 2 プラントの冷熱源は、ER が 8 台、DAR が 6 台で、冷水製造能力は 617.9 GJ/h である。冷却塔は、合計 20 セルで 2 つの系統に分かれている。センタープラントと同様に機器の組み合わせにより通水経路が変化する。温熱源は、WB と PTU が各 1 台、SB が 3 台で、蒸気製造能力は 0.8 MPa 換算で 155.5 t/h である。

2. 熱需要の予測

2.1 予測対象

本章の対象は DHC にとっての熱需要であり、要求される製造熱量と言い換えられる。需要家で消費される熱量に加え、供給中の放熱ロス分を考慮する必要がある。よって熱需要としての定義は、DHC からの供給量または蓄熱槽を含めた各熱源機から発生する熱量の合計値が適切である。計測点の都合により、冷水需要は冷凍機の直送熱量と蓄熱槽の放熱量の合計、蒸気需要はセンタープラントと第 2 プラントの出口流量合計とし、各時刻における積算量を予測するものとした。

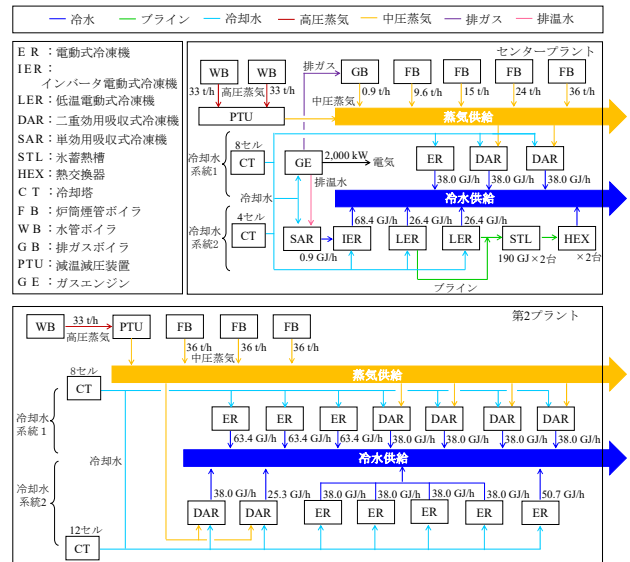


図-2 熱源系統図

表-1 各モデルで用いた説明変数

	モデル A および 重回帰分析	モデル B (日積算量)	モデル B (各時刻配分)
気象 情報	外気乾球温度, 外気相対湿度	最高外気乾球温度, 最低外気乾球温度, 平均外気乾球温度, 平均相対湿度	0 時外気温乾球温度, 1 時外気温乾球温度, ・ ・ ・ 23 時外気温乾球温度
暦 情報	曜日, 祝祭日, 日付, 時刻	曜日, 祝祭日, 日付	曜日, 祝祭日, 日付

2.2 予測モデルの概要

適した予測手法を決定するため、深層学習を用いた二種類のモデル（以下、モデル A およびモデル B とする）および重回帰分析による精度の比較を行った。表-1 に各モデルで用いた説明変数を示す。

(1) モデル A

時間の経過に従い予測対象が推移する問題は、時系列予測問題と呼ばれ、再帰型ニューラルネットワーク（Recurrent Neural Network：以下 RNN とする）が広く用いられる。そこでモデル A は、対象時刻の需要を目的変数とし、RNN で作成した。24 時間分の需要を求めるには、24 回計算を繰り返す。時刻推移を捉えるパラメータである再帰長さは、72 時間とした。1 章 1 節にて述べた負荷の変化に追従する機能として、推論時には直近 72 時間のデータでファインチューニングを行った。なお、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。

(2) モデル B

需要の変化は次の2つの現象によると考えられ、モデル B はこれらの現象を個別に捉えることを目的とした。まず需要案件数の増加や酷暑による影響で、需要量が増加する変化が考えられる。そこで、RNN を用いたモデルで日単位の積算熱需要を予測した。再帰長さは7日とした。次に需要家の運用変化やテナント入れ替わりによる負荷形態の変化が考えられる。そこで、ニューラルネットワーク (Neural Network) を用いたモデルで、日積算熱量の各時刻への配分を予測した。モデル B は2つのモデルの予測値を組み合わせて、各時刻の需要を予測する。なお、両モデルとも推論時には、前項と同様の理由から、直近7日間のデータによるファインチューニングを行った。

(3) モデルの評価

2019年4月から2020年3月までのデータを学習させ、2020年4月から2021年3月までのデータでテストを行った。なお、推論時の外気温および外気湿度については、天気予報の誤差を想定し、予報値ではない実績値に標準偏差 1.0 のノイズを付与した。式 (1) により、各モデルによる予測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。

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

ここに、

- y_i : 実際の値 [GJ]
- \hat{y}_i : 予測した値 [GJ]
- n : データ数 [-]

RMSE は、モデル A が 14.7 GJ、モデル B が 16.7 GJ、重回帰分析が 57.7 GJ であった。RMSE は、重回帰分析と比較し、モデル A およびモデル B が小さい。モデル A と比べモデル B の RMSE は 2.0 GJ 大きい、期間最大需要の 689.3 GJ の 0.3 %未満であり優位な差ではない。よってモデル A とモデル B の定量的な精度は、同程度である。2020年9月8日から9月14日の結果を抜粋し、図-3 に示す。9/9の最高気温は32.9℃、9/12の最高気温は25.1℃であり、季節の移り目である。9/12における最大絶対誤差は、モデル A が 104 GJ、モデル B が 62 GJ であり、モデル B が小さい。モデル A の予測値は、冷熱需要が大きい7:00から18:00にかけ、実際の値の付近で上下に不安定な値を示す。一方でモデル B の予測値は、おおよそ気温に相関し、なだらかな丘状に予測する傾向がある。本検討が最適運転計画システムにおける運用を見据えた需要予測であることを踏まえると、モデル A の特徴である予測値が上下する傾向は、熱源機の頻繁な起

動停止を引き起こす懸念がある。熱源機の起動直後は熱の製造が安定しないため、頻繁な起動と停止により地域への熱供給に影響を及ぼす可能性がある。また、機器の早期劣化リスクも考慮しなければならない。そのため総合的に判断し、モデル B が本システムに採用する手法として適していると判断した。

2.3 冷水製造熱量の感度解析

モデル B の日積算需要予測モデルについて、説明変数またはチューニングに用いるデータ期間を変化させ、感度解析を行った。テスト時の外気温および外気湿度には、前節と同様に標準偏差 1.0 のノイズを付与した。

(1) 説明変数による感度解析

表-2 に解析 Case の一覧を示す。表-1 の説明変数を固定とし、外気の水蒸気分圧、前日の冷水需要熱量および前日の蒸気需要量の3項目について、予測に与える影響を調査した。2019年4月から2021年9月までのデータを学習させ、2021年10月から2022年9月までのデータでテストを行った。なお、表-2 中にはテストの RMSE をあわせて記した。Case 0 は、前節と同様の説明変数であり、RMSE は 18.8 GJ であった。他の Case の RMSE は 17.6 GJ から 19.6 GJ で、いずれの項目も予測精度への影響は小さい。最も RMSE が小さいのは、外気の水蒸気分圧を加えた場合であった。外気の水蒸気分圧は、空調の除湿負荷に影響するため、冷熱需要にも影響していると推察される。




図-3 代表期間における予測結果の比較

表-2 説明変数の感度解析 Case 一覧 (冷水)

Case 番号	0	1	2	3	4	5	6	7	
説明変数	外気の水蒸気分圧	—	○	—	—	○	○	—	○
	前日の冷水需要熱量	—	—	○	—	○	—	○	○
	前日の蒸気需要量	—	—	—	○	—	○	○	○
RMSE [GJ]	18.8	17.6	19.2	18.4	18.9	17.8	19.6	18.8	

(2) チューニング期間による感度解析

移り変わる需要に追従するため、直近のデータによるファインチューニングを行っている。チューニングに用いるデータ期間が短いと、データ数が不足し過学習となる恐れがある。一方で、データ期間が長いと、需要傾向が変化する以前のデータをチューニングに使用してしまい、感度が鈍くなる懸念がある。そこでチューニングに用いるデータの適した期間を調査するため、データ期間を変数に感度解析を行った。負荷の傾向が曜日に相関していることから追加学習させるチューニングデータの期間を0日、7日間、14日間および28日間の4 Case で検討を行った。チューニングデータ期間による解析結果を図-4に示す。チューニング0日では、プロット近似式の傾きが約0.87であり、全体的に少なく予測されている。一方、7日、14日および28日では、近似式の傾きが1.0に近づいており、チューニングにより需要の変化に対応できることを確認した。RMSEは、28日が最も小さく17.3 GJであった。14日と28日のRMSEの差が0.3 GJと小さいことから、チューニングデータの期間は14日程度で満足していると推察される。2022年6月22日から6月28日の結果を抜粋し、図-5に示す。6/22の最高気温は26.1℃、6/27の最高気温は33.8℃であり、季節の移り目である。0日と比較し7日、14日および28日の予測値は近い値を示している。いずれもチューニングによる効果は同様の傾向を示していると推察される。

2.4 蒸気量予測の感度解析

モデルBを蒸気需要量の予測に転用し、冷水需要予測と同様に感度解析を行った。まず説明変数の感度解析を行った。解析Caseの一覧を表-3に示す。テストのRMSEをあわせて記した。冷水と同様に、2019年4月から2021年9月までのデータを学習させ、2021年10月から2022年9月までのデータでテストを行った。なお、蒸気流量計測に不備があったため、2022年3月20日から2022年4月30日のデータを除外した。説明変数の感度解析の結果、Case 8のRMSEが最も小さく5.8tであった。期間最大需要の182.3tの4%未満であり十分に小さい。Case 8は、平均湿度および外気の水蒸気分圧を除外した条件である。蒸気の用途には、暖房のほか給湯が含まれるため、相対的に潜熱処理に用いる熱量が減少することから、湿度に関する変数は不要であったと推察される。つぎにチューニング期間による感度解析を行った。解析パラメータは、0日、7日、14日および28日である。チューニング0日では、プロット近似式の傾きが約0.96であった。冷水と同様に少なく予測される傾向を確認した。一方、チューニング7日、14日および28日の結果では、

いずれも傾きが1.0に近づいており、チューニングにより需要変化が捉えられていると推察される。チューニング期間による感度解析の結果を表-4に示す。最もRMSEが小さいのは、14日補正の5.8tであった。




図-4 チューニングデータ期間による解析結果




図-5 代表期間における予測結果の比較

表-3 説明変数の感度解析 Case 一覧 (蒸気)

Case 番号	0	1	2	3	4	5	6	7	8	
説明変数	外気の水蒸気分圧	—	○	—	—	○	○	—	○	—
	前日の冷水需要熱量	—	—	○	—	○	—	○	○	○
	前日の蒸気供給量	—	—	—	○	—	○	○	○	○
	平均外気湿度	○	○	○	○	○	○	○	○	—
RMSE [t]	6.5	6.5	6.5	6.0	6.0	5.9	6.0	5.8	5.8	

表-4 チューニング期間の感度解析結果

チューニング期間	0日	7日	14日	28日
RMSE [t]	6.0	6.9	5.8	5.9

3. プラントエネルギー消費量の予測

3.1 機器単体モデルの作成

熱源システムのモデルは、オブジェクト指向の概念で構築した。機器ごとにオブジェクト化することで、機器の更新や新設に際して柔軟に対応可能である。消費エネルギーを算出するモデルのほか、エネルギー収支の計算に必要な高圧蒸気と中圧蒸気の変換効率モデル、STL に付属する放熱熱交換器の熱交換効率モデル、STL の蓄熱槽効率モデルを作成した。作成したモデル数は 200 である。

(1) 冷凍機

説明変数と目的変数の一覧を表-5 に示す。既報³⁾にて、IER の主電動機を対象とした消費電力の予測モデルについて報告している。本研究では、ER 主電動機の消費電力および DAR 再生器の消費蒸気においても同様の手法を採用し、ファインチューニングを組み込んだニューラルネットワーク (Neural Network : 以下、NN とする) を用いた。補機の消費電力は、冷凍機の運転状態による二項分類モデルとした。検証に用いたデータは、2019 年 4 月 1 日から 2022 年 9 月 30 日までの 42 カ月分で、学習に 8 割、テストに 2 割を使用した。なお、計測器の故障があったため、LER-1 および DAR-1 においては、一部の期間データを除外した。式 (1) により、各モデルによるテストの RMSE を算出した。冷凍機のテスト結果を表-6 に示す。主電動機消費電力の RMSE は、最小で 20.4 kW、最大で 51.5 kW であった。再生器消費蒸気の RMSE は、最小で 156.5 kg/h、最大で 228.9 kg/h であった。補機消費電力の RMSE は、最小で 0.4 kW、最大で 5.9 kW であった。主電動機消費電力と再生器消費蒸気の RMSE は、全ての機種で定格値の 5.0%未満であった。一方で、補機消費電力の RMSE は、一部の機種で定格値の 15%超となった。これは定格値に対して、計量パルスレートが大きいことに起因する。しかし補機の電力は、冷凍機全体の消費エネルギーのうち 1%未満であることから、プラント全体のエネルギー消費量を求める際の影響は極めて小さい。

表-5 冷凍機の説明変数と目的変数

機種	目的変数	説明変数
ターボ 冷凍機	主電動機 消費電力	冷水流量、冷水出口温度、冷水出入口温度差、冷却水流量、冷却水入口温度
	補機 消費電力	運転状態 (起動 or 停止)
吸収式 冷凍機	再生器 消費蒸気	冷水流量、冷水出口温度、冷水出入口温度差、冷却水流量、冷却水入口温度、蒸気圧力
	補機 消費電力	運転状態 (起動 or 停止)

表-6 冷凍機のテスト結果

機種	機番	定格値			テストの RMSE		
		主電動機 消費電力 kW	再生器 消費蒸気 kg/h	補機 消費電力 kVA	主電動機 消費電力 kW	再生器 消費蒸気 kg/h	補機 消費電力 kW
ER-1	-A	2,044		14	24.7	-	0.5
	-B				20.4		
ER-2	-A	2,150		14	47.0		0.4
	-B				45.5		
ER-3	-A	2,150		14	35.4		0.4
	-B				34.3		
ER-4	-A	2,150		14	25.6		0.4
	-B				32.5		
ER-5	-A	2,150		14	22.2		0.4
	-B				22.0		
ER-6	-A	2,501		17	32.5		0.5
	-B				28.2		
ER-7	-A	3,082		17	29.1		0.5
	-B				32.4		
ER-8	-A	3,278		16	34.9		0.5
	-B				27.6		0.5
ER-9	-A	3,278		16	34.3		0.5
	-B				27.6		0.5
LER-1	-A	1,956		18	31.6		0.4
	-B				31.8		
LER-1	-A	1,956		18	28.2		0.4
	-B				33.1		
IER-1	-A	3,379		40	29.2		0.4
	-B				51.5		0.5
DAR-1	-A	10,770	70		177.6		5.6
	-B				173.5		5.8
DAR-2	-A	10,770	70		160.3		5.7
	-B				160.7		5.6
DAR-3	-A	10,770	70		174.0		5.2
	-B				223.3		5.4
DAR-4	-A	10,770	70		172.5		4.8
	-B				156.5		4.9
DAR-5	-A	10,770	70		181.5		5.4
	-B				205.5		5.8
DAR-6	-A	10,770	50.8		184.4		5.3
	-B				157.5		5.1
DAR-7	-A	10,770	50.8		194.2		5.8
	-B				170.3		5.9
DAR-8	-A	7,200	50.8		228.9		5.7
	-B				182.6		5.0

(2) 蒸気ボイラ

説明変数と目的変数を表-7に示す。ボイラの蒸気発生量とガス消費量には、線形相関があることが知られており、線形回帰モデルを使用した。検証に用いたデータは、2019年4月1日から2022年9月30日までの42カ月分で、学習に8割、テストに2割を使用した。ボイラのテスト結果を表-8に示す。消費ガスのRMSEは、最小で3.3 Nm³/h、最大で7.3 Nm³/hであった。全ての機種で定格値の1.0%未満であった。消費電力のRMSEは、最小で0.7 kW、最大で8.4 kWであった。定格値の1.1%から35.1%であり、ガス消費量と比較し大きい傾向であった。これは、冷凍機の補機電力と同様で、定格値に対して、計量パルスレートが大きいことに起因している。ボイラの電力は、ボイラ全体の消費エネルギーのうち2%未満であり、プラント全体のエネルギー消費量を求める際の影響は極めて小さい。

(3) 冷却塔

冷却塔モデルは、NNで作成した。説明変数と目的変数を表-9に示す。冷却水流量負荷率は、通水している冷却塔の定格流量に対する現在流量の比であり、式(2)により算出した。

$$F_{rate} = \frac{F_{pv}}{\sum F_{defined}} \quad \dots\dots(2)$$

ここに、

- F_{rate} : 冷却水流量負荷率 [-]
- $F_{defined}$: 通水中冷却塔の定格流量 [m³/h]
- F_{pv} : 冷却水の現在流量 [m³/h]

冷凍機と冷却塔の組み合わせにより、通水経路が変化し、冷却塔出口温度に相当する温度計測点が異なる。そのため、冷却水が系統1のみ通水時、系統2のみ通水時および両系統通水時の3つの運転条件に分けてモデルを作成した。また、第2プラントにおいて、2021年3月に翼角を調整しており、冷却能力とファン動力の相関が変化している。予測精度への影響を併せて調査した。センタープラントの検証には、2019年4月1日から2022年9月30日までの42カ月分のデータを用い、学習に8割、テストに2割を使用した。第2プラントの検証は、学習に異なるデータを用いて2Caseで行った。Case Aの学習には、翼角調整前である2019年4月1日から2021年2月28日までのうち、8割のデータを使用した。Case Bの学習には、翼角調整後である2021年3月1日から2022年9月30日までのうち、8割のデータを使用した。いずれのCaseもテストには、2021年3月1日から2022年9月30日までのうち、2割のデータを使用した。両系統とも運転時のRMSEは、Case Aの学習が94.8 kW、テスト

が192.4 kWであり、Case Bの学習が100.3 kW、テストが102.7 kWであった。Case Aは、学習と比較しテストの精度が低い。一方、Case Bの精度は、いずれも同程度であった。Case AおよびCase Bにおける実績電力と予測電力のプロットを図-6に示す。Case Aの予測電力は

表-7 蒸気ボイラの説明変数と目的変数

機種	目的変数	説明変数
水管式ボイラ 炉筒煙管式ボイラ	消費ガス	蒸気発生量
	補機消費電力	蒸気発生量

表-8 蒸気ボイラのテスト結果

機番	定格値		テストのRMSE	
	消費ガス Nm ³ /h	消費電力 kW	消費ガス Nm ³ /h	消費電力 kW
WB-1	2,360	110	4.9	5.5
WB-2	2,360	110	7.3	4.8
WB-3	2,350	110	4.7	8.4
SB-1	566	30	3.3	0.7
SB-2	885	55	3.8	4.8
SB-3	1,414	90	6.3	5.5
SB-4	2,141	132	4.4	1.4
SB-5	2,141	132	7.1	2.9
SB-6	2,141	132	7.2	2.3
SB-7	2,141	132	7.3	2.5
GB	-	3.7	-	1.3

表-9 冷却塔の説明変数と目的変数

プラント	目的変数	説明変数
センタープラント	消費電力	ターボ冷凍機製造熱量、 吸収式冷凍機製造熱量、 冷却水流量合計、 冷却水流量負荷率、 外気湿球温度、 発電量、 系統1運転台数、 系統2運転台数、 系統1出口温度 ^{†1} 、 系統1アプローチ温度 ^{†1} 、 系統2出口温度 ^{†2} 、 系統2アプローチ温度 ^{†2}
第2プラント	消費電力	ターボ冷凍機製造熱量、 吸収式冷凍機製造熱量、 冷却水流量合計、 冷却水流量負荷率、 外気湿球温度、 系統1出口温度 ^{†1} 、 系統1アプローチ温度 ^{†1} 、 系統1運転台数 ^{†1} 、 系統2出口温度 ^{†2} 、 系統2アプローチ温度 ^{†2} 、 系統2運転台数 ^{†2}

注 ^{†1} 系統1のみ通水時、両系統通水時に限り使用
^{†2} 系統2のみ通水時、両系統通水時に限り使用

Case B の予測電力と比較し、実際の値より大きい傾向であった。これらより機器の能力変更は、消費エネルギーの予測精度に影響があり、オーバーホールや整備には注意が必要であることが示唆された。また精度の低下を防ぐには、能力変更後のデータで再学習が必要であると考えられる。以降の検討には、テストの RMSE が小さい Case B を用いる。冷却塔のテスト結果を表-10 に示す。センタープラントの RMSE は、最小で 34.9 kW、最大で 46.6 kW であった。第 2 プラントの RMSE は、最小で 23.5 kW、最大で 102.7 kW であった。いずれも定格値の 4 % 未満であった。

(4) その他のモデル

その他のモデルは、線形回帰モデルを使用した。ポンプのモデルは、流量を説明変数とし消費電力を予測した。冷水ポンプの RMSE は、最小で 0.3 kW、最大で 10.9 kW であった。冷却水ポンプの RMSE は、最小で 0.5 kW、最大で 8.6 kW であった。ブラインポンプの RMSE は、最小で 0.9 kW、最大で 1.2 kW であった。PTU のモデルは、中圧蒸気流量を説明変数とし高圧蒸気流量を予測した。RMSE は、最小で 0.1 t/h、最大で 0.2 t/h であった。放熱熱交換器のモデルは、冷水側熱量を説明変数としブライン側熱量を予測した。RMSE は 0.27 GJ/h であった。STL のモデルは、放熱量を説明変数とし蓄熱量を予測した。RMSE は 0.13 GJ であった。

3.2 プラント全体の消費エネルギー量予測

全てのモデルを組み合わせ、プラント全体の消費エネルギー量予測時の精度を確認した。図-7 に電力量の予測およびガス量の予測結果を示す。RMSE は、電力量が 416.2 kWh、ガス量が 72.3 m³/h であった。相関係数は 0.99 を超えており、十分にプラント全体のエネルギー消費量の傾向を捉えていることを確認した。

4. 最適化計算

4.1 目的関数

目的関数は、2 パターンとした。1 つ目の目的関数（以下、O1 とする）は、24 時間あたりの CO₂ 排出量を最小とした。2 つ目の目的関数（以下、O2 とする）は、24 時間あたりの CO₂ 排出量および電力ピーク調整対象である 13 時から 16 時までの電力量のパレート最適解とした。CO₂ の算出は、消費電力量とガス量に原単位を乗じて求めた。消費電力量とガス量の算出には、3 章のモデルを用いた。設計変数は冷凍機 40 台およびボイラ 10 台の各時刻における負荷率とした。停止している機械は負荷率 0 % として扱う。




図-6 Case A と Case B の比較

表-10 冷却塔のテスト結果

		定格消費電力	テストの RMSE
CP CT1~12	系統 1 のみ運転	1,440 kW	34.9 kW
	系統 2 のみ運転	1,440 kW	43.7 kW
	両系統とも運転	1,440 kW	46.6 kW
2P CT1~20	系統 1 のみ運転	1,280 kW	23.5 kW
	系統 2 のみ運転	1,920 kW	37.9 kW
	両系統とも運転	3,200 kW	102.7 kW




図-7 全体のテスト結果

4.2 計算条件および制約条件

蓄熱の使用はピーク調整と連動とし、蓄熱運転は 22 時に起動し、固定負荷率で蓄熱、満蓄で停止する。放熱運転は、10 時に起動、定格で放熱し、残蓄ゼロで停止する。LER の冷水追いかけ運転には制限を設けない。GE は、5 月から 9 月の 8:00 から 21:59 まで運転し、GB と SAR は連動とする。冷水温度は行き 6.0 °C、還り 13.0 °C で設定した。供給冷水流量は、往還温度差 7K から算出した。各冷凍機の冷水流量は、負荷率に見合うため変数である。各冷凍機の冷却水流量は定格流量とした。冷却塔の運転台数は、冷凍機の運転に合わせて定格冷却水流量を積算し、冷却水流量の負荷率に基づいて決定した。冷却塔の冷却水出口温度は外気湿球温度+4 °C とした。その他の制約条件として、以下の 8 項目を設けた。

- 1) 各時刻における冷凍機製造熱量と蓄熱槽放熱量の和は、冷水需要より大きい。

- 2) 各時刻におけるボイラ発生蒸気量は、蒸気需要量とDARの消費蒸気量の和より大きい。
- 3) センタープラントで、同時刻に起動できるDARの台数は4台以下とする。
- 4) 第2プラントで、同時刻に起動できるDARの台数は4台以下とする。
- 5) 起動した冷凍機は、2時間停止できない。
- 6) 停止した冷凍機は、2時間起動できない。
- 7) センタープラントの消費電力は、いずれの時刻もセンタープラントの契約電力以下とする。
- 8) 第2プラントの消費電力は、いずれの時刻も第2プラントの契約電力以下とする。

4.3 アルゴリズム

非線形を含む混合整数計画問題であるうえ設計変数が

多いことから、厳密解法は困難であると判断し、メタヒューリスティクスである遺伝的アルゴリズム (Genetic Algorithm : 以下、GA とする) を採用した。

4.4 検討対象日

2022年8月2日(火) 22:00からの24時間を代表日とした。最高外気温は35.2℃で、猛暑日である。熱源の運転はピーク調整を実施しており、24時間あたりのCO₂排出量は488t、ピーク調整対象時刻の消費電力量は6,033kWhである。

4.5 結果

O1およびO2における最適化後のヒートマップを図-8および図-9に示す。横軸が時刻、縦軸が熱源機種、色の濃淡が製造熱量を表しており、熱源機の起動時刻、停




図-8 O1における最適化の結果




図-9 O2における最適化の結果

止時刻および負荷率が読み取れる。いずれの結果も、電動式の機種が終日運転し、DAR が昼間に増段されるという傾向である。LER による昼間の追いかけ運転は使用されていない。インバータ搭載機である IER-1 は、終日運転しつつ負荷率の変化が確認できることから、機械学習を通じて部分負荷特性が優れているという認識がなされていると推察される。両結果を比較すると、O2 では 12 時から 17 時にかけて IER の製造熱量を減らしセンタープラントの消費電力を下げ、ピーク調整機能が有効に働いていると考えられる。供給熱量は、蓄熱槽からの放熱と第 2 プラントの冷凍機運転台数を増やすことで賄っている。ボイラの運転時間は吸収式に相関しており、地域への蒸気供給と同時に冷凍機の消費量が反映されている。

O2 の CO₂ 排出量は 474 t で最適化前の 97.1 %、ピーク調整対象時刻の消費電力量は 6,148 kWh で最適化前の 101.9 %であった。オペレータが判断したピーク調整運転とおおむね近い結果であった。O1 の CO₂ 排出量は 436 t で最適化前の 89.3 %、ピーク調整対象時刻の消費電力量は 6,649 kWh で最適化前の 110.2 %であった。O2 と比較し、CO₂ 排出量がより小さくなる解を選択しており、目的関数に従った最適化が行われていることを確認した。制約条件は全ての時刻で満たされており、本手法を用いることで DHC の熱源における運転計画を導出できることを示した。

おわりに

本報では、DHC の熱源機における最適運転計画システムの構築を目的に、要素技術の感度解析と最適化手法の有効性を確認した。その結果、機械学習による熱需要予測モデルおよびプラントのエネルギー消費量予測モデルと GA を組み合わせることで、DHC の運転計画を導くことが可能であることを示した。

謝 辞

本報の執筆にあたり、みなとみらい二十一熱供給株式会社にデータをご提供いただいた。ここに謝意を表する。

参 考 文 献

- 1) 山本 正幸 ほか：非線形性を有する空調用熱源プラントの最適運転制御に関する研究（第 1 報）冷凍機とポンプ動力の非線形性を線形計画法で扱うための手法とその効果，空気調和・衛生工学会論文集，No.122(2007-05)，pp9-16
- 2) 中村 安弘 ほか：蓄熱槽を有する空調用熱源プラントの最適運転制御，空気調和・衛生工学会論文集，No90(2003-07)，pp.121-130
- 3) 尾形 甫 ほか：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，空気調和・衛生工学会大会学講演論文集，第 2 巻(2023-09)，pp.109-112