



東京大学
生産技術研究所
Institute of Industrial Science,
The University of Tokyo

Smartな蓄熱制御 — IEA ECES Annex 37の報告

東京大学生産技術研究所・大岡龍三



iea

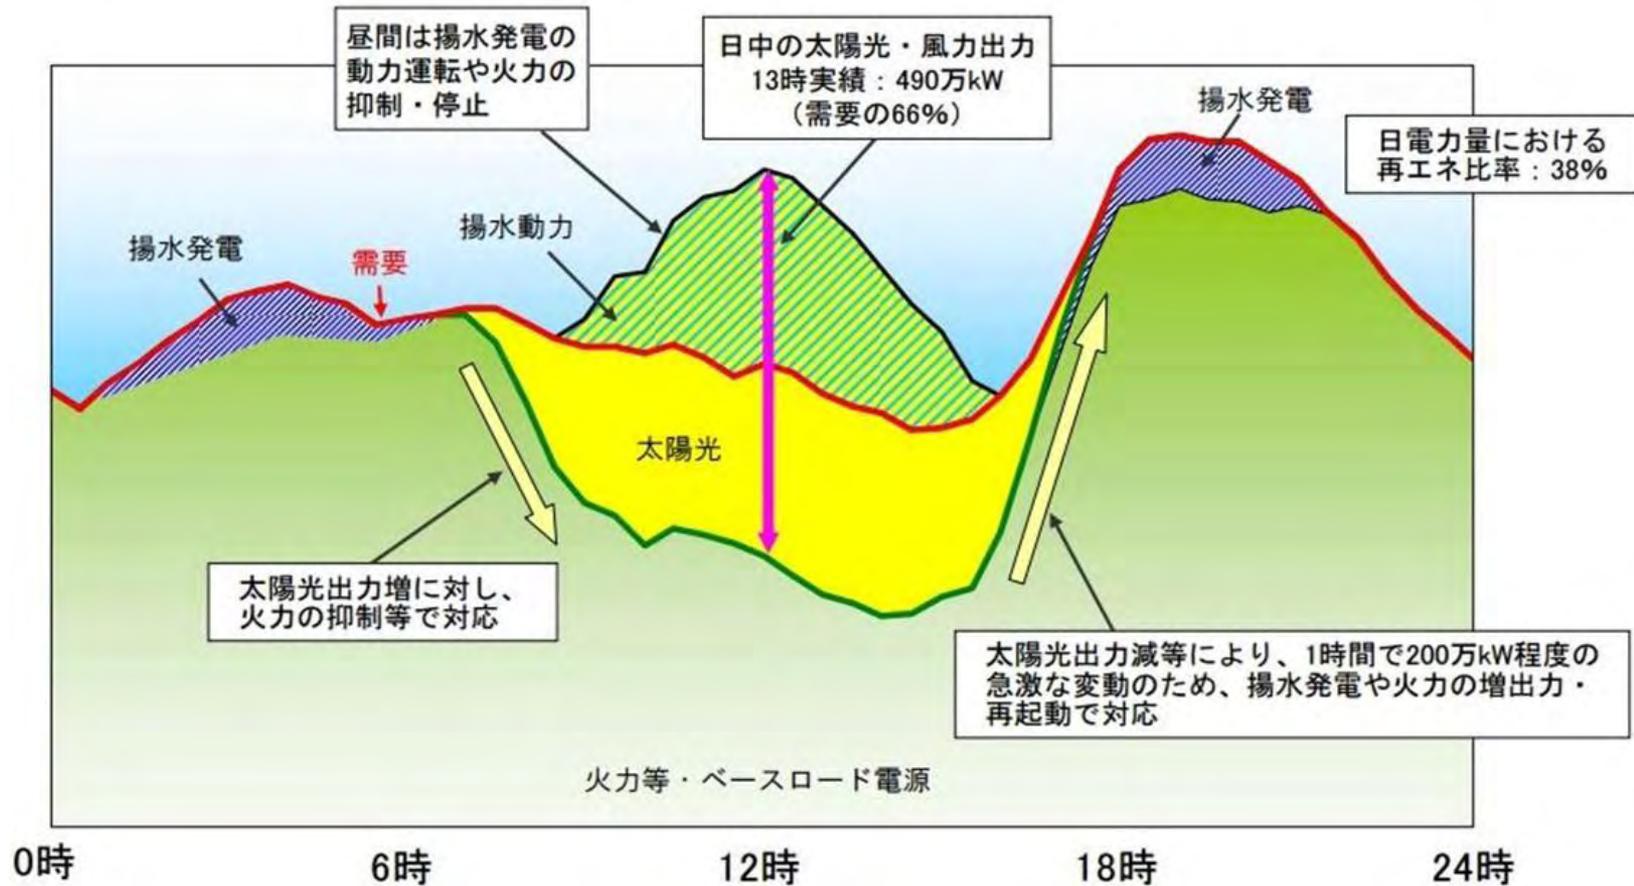


energy
storage

IEA Technology Collaboration Programme

背景

ダックカーブは日本においても出現している(九州電力, May 4th 2016)



背景

蓄エネルギー技術は、需要と供給のミスマッチを解消する技術として期待されている。

もし蓄エネルギーの容量が無限大であればこのミスマッチの問題は解決する。しかしながら、資源とコストの制限より容量を無限大にすることは不可能である。

したがって、限られた蓄エネルギー設備のリソースを有効に使うことが非常に重要である。

背景

また、ここ数年の人工知能の発達が目覚しく、人工知能の利用を前提とした蓄エネルギー貯蔵システムの設計・制御方法の再構築が必要である。

またここでいう蓄エネルギー技術は蓄電・蓄熱すべてを含むが本発表では特に蓄熱技術を中心に発表する。

熱エネルギーは電気エネルギーに比べて取り扱いが面倒であるが、状況によれば熱は熱として利用するほうが省エネルギーに資する場合もある。

IEA ECES Annex 37の設立

このような状況の下、国際エネルギー機関IEA (International Energy Agency) のECES (Energy Conservation and Energy Storage) では2020年5月にAnnex 37 (Smart Design and Control of Energy Storage Systems)を設立した。

Annex 37の目的は下記のとおりである。

このAnnexでは、需要と供給のギャップを効率的に埋めるために、建物と地域の両方の蓄エネルギー貯蔵システムのスマートな設計と制御戦略を調査します。

具体的には、近年著しく発展した人工知能を検証し、スマートな設計・制御システムに大きく貢献させることを目指す。

研究結果は、設計資料および運用ガイドラインとして整理される。

Members

OA candidate: Ryozo Ooka

TASK	建物	地域
TASK A Prediction method	Ruchi Chaudhary (UK) Enrico Fabrizio (Italy) Fariborz Haghighat and Behrang Talebi (Canada) Claudio Del Pero (Italy) Ryozo Ooka (Japan)	
TASK B Component and system modelling	Gilles Fraise (France,), Mohamed Mankibi (France) Umberto Berardi (Canada). Ryozo Ooka (Japan)	Massimo La Scala (Italy) Mariagrazia Dotoli (Italy)
TASK C Smart design/integration method	Alireza Afshari (Demark), Gilles Fraise (France) Mohamed Mankibi (France), George Zhang (China) Enrico Fabrizio (Italy,), Umberto Berardi (Canada) Sasan Sadrizadeh (Sweden)	Massimo La Scala (Italy) Mariagrazia Dotoli (Italy)
TASK D Smart control/optimization method	Umberto Berardi (Canada). Fariborz Haghighat Behrang Talebi (Canada), Parham Mirzaei (UK) Alireza Afshari (Demark), George Zhang (China) Sasan Sadrizadeh (Sweden), Ryozo Ooka (Japan)	Massimo La Scala (Italy) Mariagrazia Dotoli (Italy)

CANADA, CHINA, DENMARK, FRANCE, ITALY, JAPAN, SLOVENIA, SWEDEN, TURKEY, UK, US, (11 countries) Other countries that are interested in.

Supporting Companies



Tokyo Electric Power Company



Dreams into Reality for a Sustainable Future
TAKENAKA

Takenaka Cooperation



DAI-DAN CO.,LTD.

DAIDAN Co. LTD



BBA:
Industrial Consulting
Engineering Firm

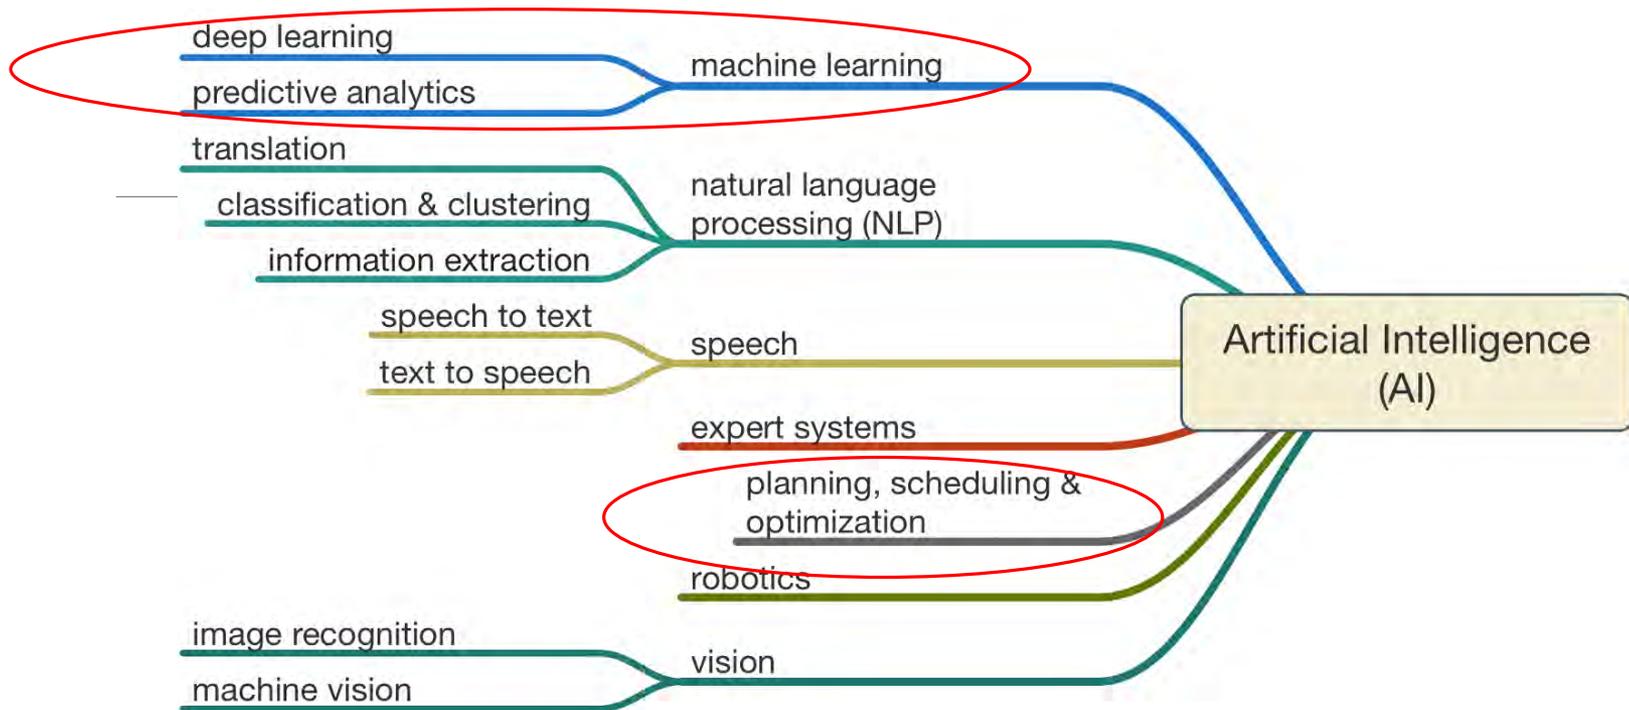


Ouellet Canada inc.



Institut de recherche
d'Hydro-Québec

建築・都市設備運用で必要となるAI

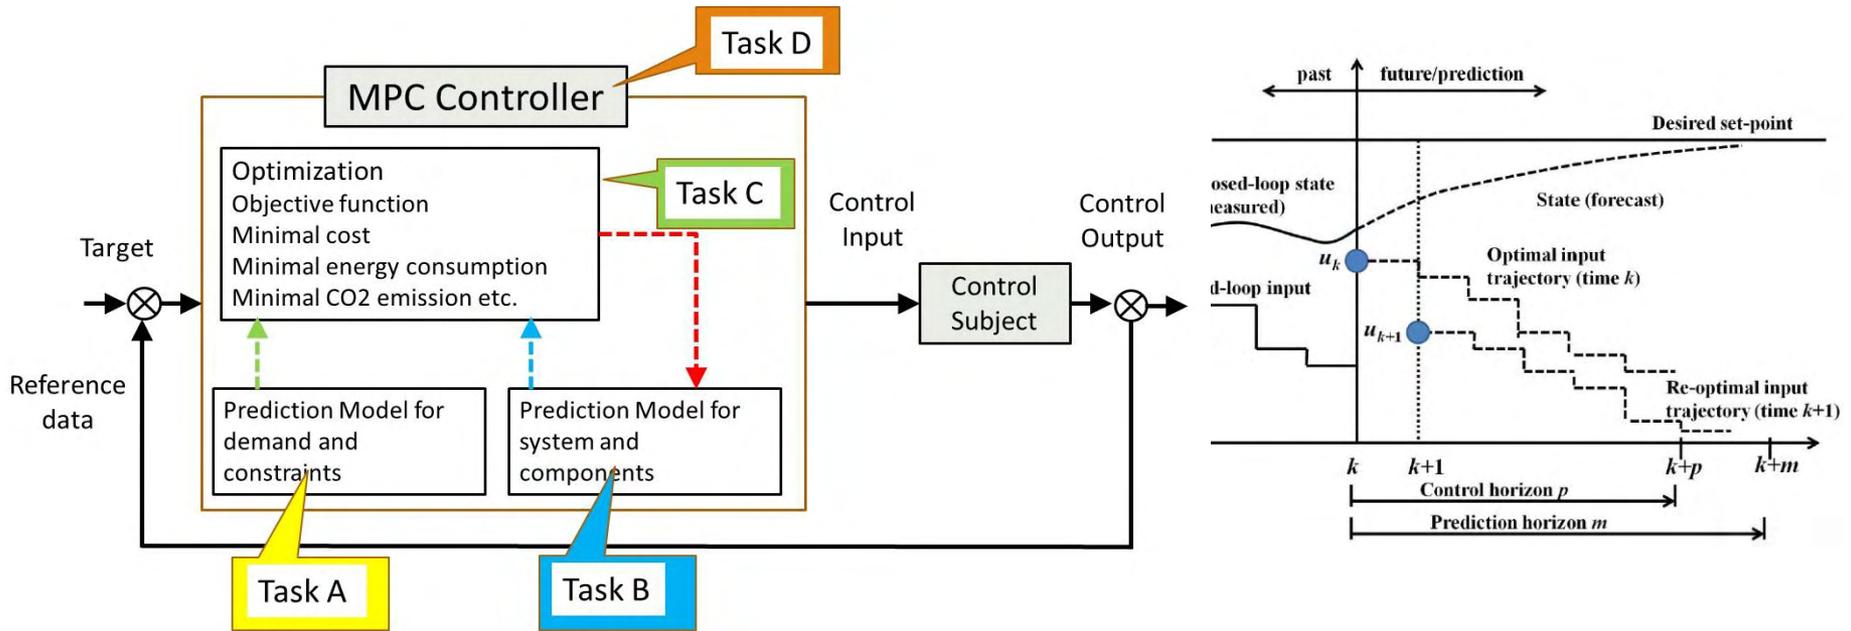


<https://medium.com/ml-ai-study-group/ai-mind-map-a70dafcf5a48>

- 機械学習によるシステム特性・機器特性のモデル化
→ 特徴量抽出によるモデリング能力
- メタヒューリスティクスによる建築都市の設計・運用最適化
→ 強力な探索能力

最終成果物:蓄エネルギーシステムのモデル予測制御

モデル予測制御(MPC)は、予測モデルと最適化方法に基づいて、システムの将来の動作を予測して、最適な制御入力シーケンスを決定する。



克服すべき課題

通常、制御信号の間隔は1時間以内が求められる。

そのために高精度の高速予測モデルと最適化手法を開発する必要がある。

機械性能の劣化などの性能変化の情報の更新も必要です。

人工知能は、これらの問題を解決するための有望なツールになる。

人工知能を用いた 空調熱源システムのモデル予測制御

Model predictive control of building energy system
using artificial intelligence

モデル予測制御

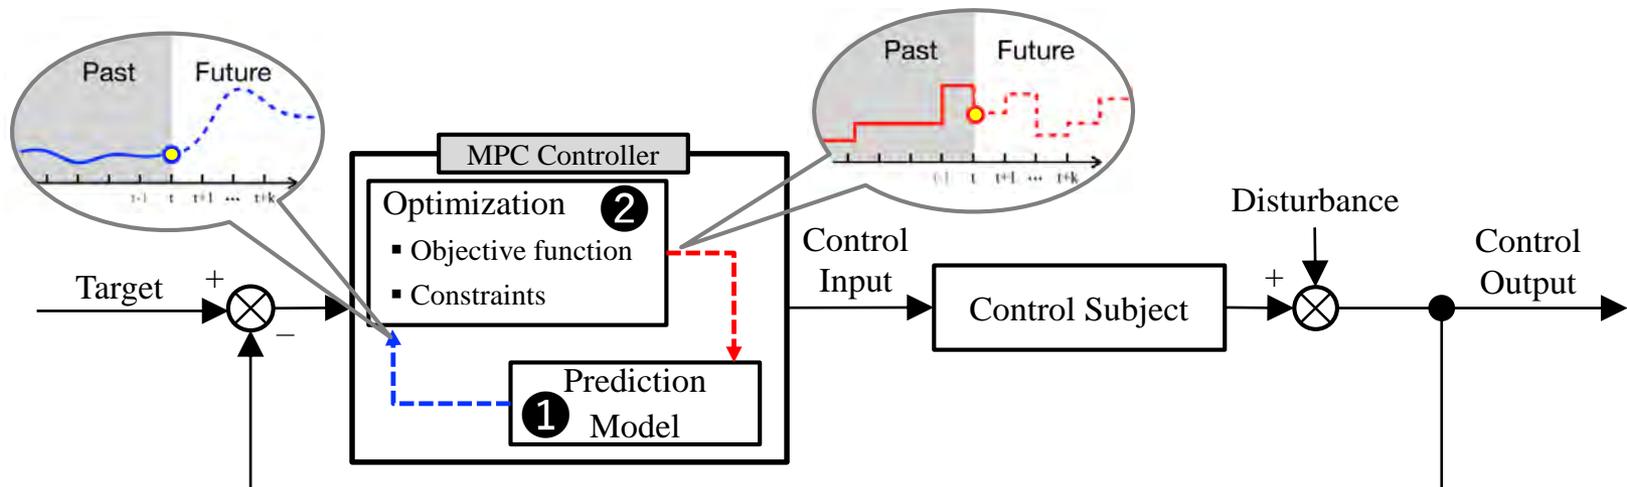
• MPCの性能を左右する構成要素

① 予測モデル

= 制御対象の挙動を予測するモデルの精度

② 最適化手法

= 制御入力 of 最適解を探索する最適化アルゴリズムの効率性



MPCの性能を左右する構成要素

① 予測モデル⁵⁾

- White-box model
- Grey-box model
- **Black-box model**

→ 空調熱源システムは、多様な機器で構成されているためモデル化が複雑

→ 適切なデータを使用して構築できる場合、**Black-box**は高精度かつ高速で活用できる⁶⁾

② 最適化手法⁷⁾

- 数理計画的手法
- **メタヒューリスティクス的手法**

→ **MPC**では、実時間で最適化問題を解く必要があり、計算負荷が実用上の障害である

→ **メタヒューリスティクス手法**は、収束速度が速く制約条件の処理が効率的である

5) ASHRAE, ASHRAE Handbook-fundamentals, American Society of Heating, Refrigerating, Air-Conditioning, Engineers, 2009.

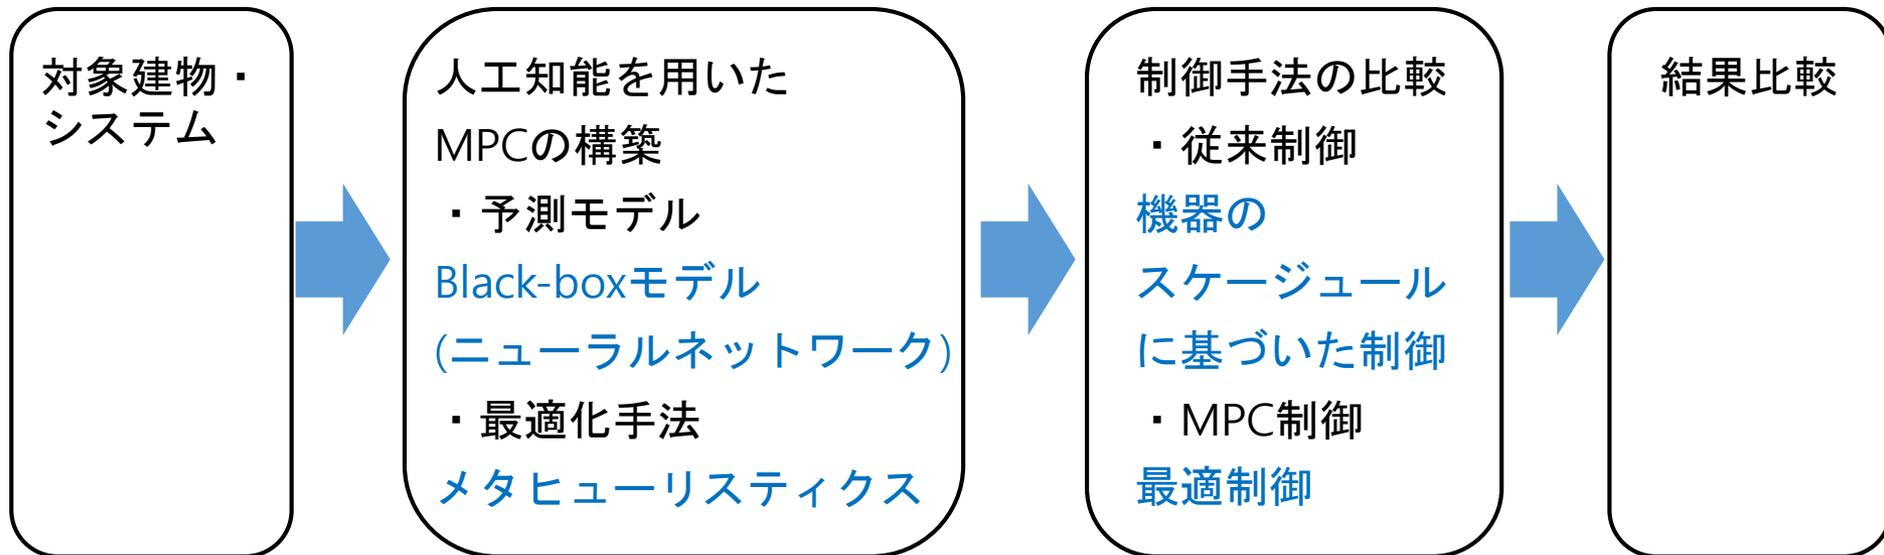
6) M. Killian, M. Kozek, Ten questions concerning model predictive control for energy efficient buildings, Build. Environ. 105 (2016) 403–412.

7) R. Ooka, S. Ikeda, A review on optimization techniques for active thermal energy storage control, Energy Build. 106 (2015) 225–233.

研究目的

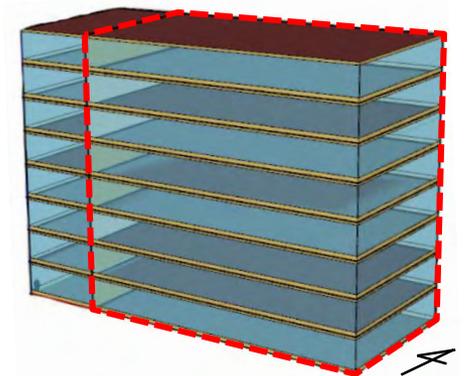
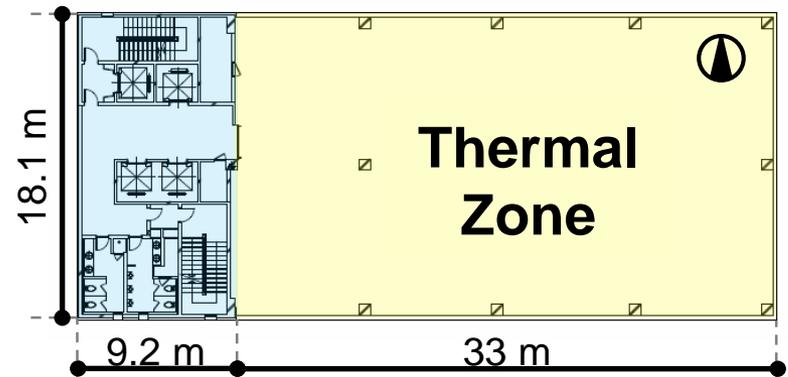
• 研究目的

人工知能を活用したMPCモデル予測制御手法を提案し、
その手法を用いた建物空調熱源システムの運用最適化の実用性を検討



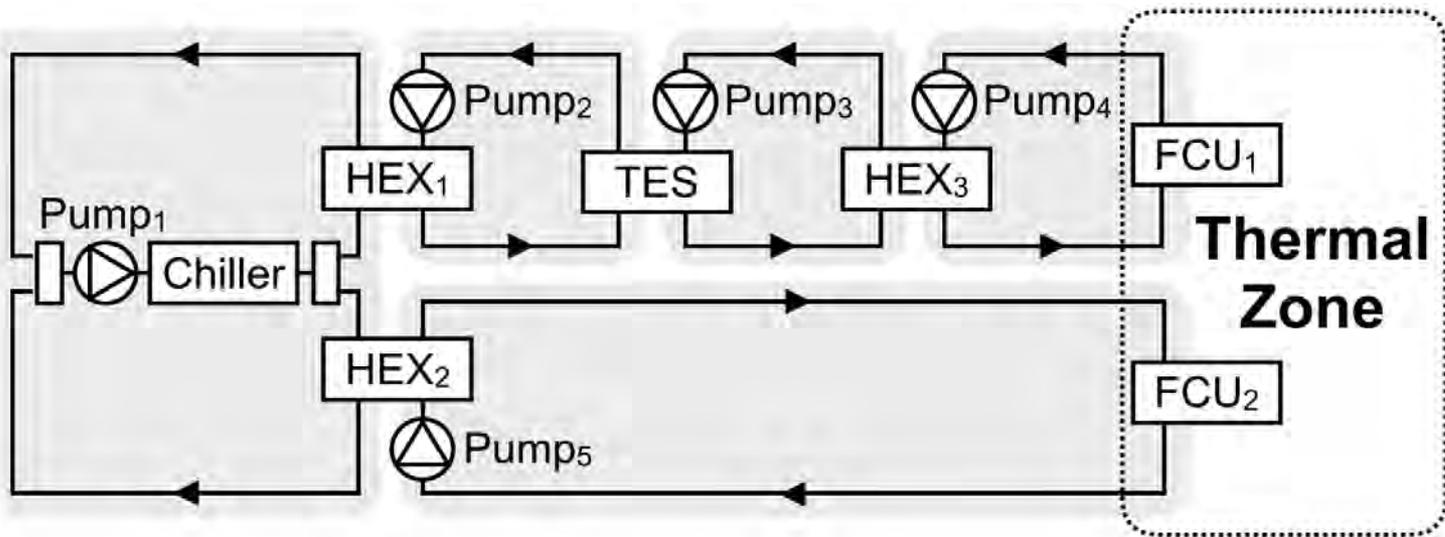
対象建物

- ・東京にある地上8階のオフィスを仮定
- ・ツール：OpenStudio, EnergyPlus
 - 解析期間：4日間 (7月17日～20日)
 - 建物外皮の熱還流率 ($W/(m^2K)$)
 - ・外壁：0.95
 - ・屋根：0.49
 - ・スラブ：0.71
 - ・窓：2.97
 - 窓面積比：80%
 - 内部発熱
 - ・照明：10 W/m^2
 - ・機器：15 W/m^2
 - ・在室者：0.92 人/ m^2 (120 W/人)
 - 空調条件
 - ・冷房運転期間：93日間 (冷房運転: 6月15日～9月15日)
 - ・運転期間：平日の在室時間帯 9:00~18:00
 - ・冷房設定温度：26 $^{\circ}C$



対象システム

- ・ 空冷式チラー (Chiller)
 - ・ 温度成層型冷水蓄熱層 (TES)
 - ・ ファンコイルユニット (FCU₁, FCU₂)
 - ・ 対向流式熱交換器 (HEX₁~HEX₃)
 - ・ 変流量ポンプ (Pump₁~Pump₅)
- **制御の操作変数**：各機器の供給側のポンプの流量値
※チラーの出口温度は、4 °Cに固定



予測モデル: ニューラルネットワーク (ANN)

- ・計算負荷が低い反面予測精度が高い
- ・操作変数であるポンプの流量値と予測すべきである教師データは、非線形関係

→ **MPCの予測モデルとして活用性が良い**

- 対象建物と設備システムの挙動を予測する目的として全4個のANNを作成

予測対象		予測するデータ (教師データ)
Thermal Zone	1	室内温度 T_{zone} ($^{\circ}\text{C}$)
	TES	蓄熱層内の最上層温度 $T_{\text{TES,top}}$ ($^{\circ}\text{C}$)
蓄熱層内の最下層温度 $T_{\text{TES,bot}}$ ($^{\circ}\text{C}$)		
Chiller	3	チラーの入口温度 $T_{\text{c,in}}$ ($^{\circ}\text{C}$)
		チラーの出口温度 $T_{\text{c,out}}$ ($^{\circ}\text{C}$)
	4	チラーの電力使用量 E_{chiller} (kWh)

ANNの学習条件

- ・学習データの合計：142,848時系列データ
- ・学習構造：4-layer feedforward type (隠れ層2層、20ニューロン)
- ・学習方法：学習データの70%をバッチ学習 (Epoch = 1,000)

・入力データと教師データ

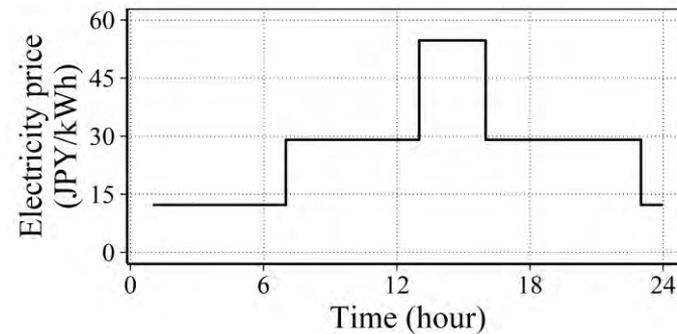
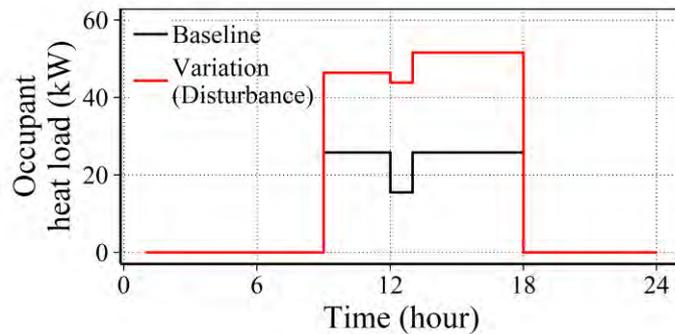
モデル評価結果

予測対象		入力データ (操作変数)	教師データ	R ²	RMSE
Thermal Zone	1	$T_{out}^t, S_{diff}^t, S_{dir}^t, N_{occu}^t, T_{zone}^{t-1}, \dot{m}_{pump1}^t, \dot{m}_{pump2}^t, \dot{m}_{pump3}^t, \dot{m}_{pump4}^t, \dot{m}_{pump5}^t$	T_{zone}^t	0.9929	0.1676 °C
TES	2	$T_{TES,top}^{t-1}, T_{TES,bot}^{t-1}, T_{zone}^t, \dot{m}_{pump1}^t, \dot{m}_{pump2}^t, \dot{m}_{pump3}^t, \dot{m}_{pump4}^t, \dot{m}_{pump5}^t$	$T_{TES,top}^t, T_{TES,bot}^t$	0.9964	0.1652 °C
Chiller	3	$T_{out}^t, RH^t, T_{zone}^t, T_{TES,top}^t, T_{TES,bot}^t, T_{c,in}^{t-1}, T_{c,out}^{t-1}, \dot{m}_{pump1}^t, \dot{m}_{pump2}^t, \dot{m}_{pump3}^t, \dot{m}_{pump4}^t, \dot{m}_{pump5}^t$	$T_{c,in}^t, T_{c,out}^t$	0.9948	0.0894 °C
	4	$T_{out}^t, RH^t, T_{zone}^t, T_{TES,top}^t, T_{TES,bot}^t, T_{c,in}^t, T_{c,out}^t, \dot{m}_{pump1}^t, \dot{m}_{pump2}^t, \dot{m}_{pump3}^t, \dot{m}_{pump4}^t, \dot{m}_{pump5}^t$	$E_{chiller}^t$	0.9999	0.031 kWh

T_{out} : Outdoor temperature (°C), RH : Outdoor relative humidity (%), S_{dir} : Direct solar irradiance (W/m²), S_{diff} : Diffuse solar irradiance (W/m²), N_{occu} : Number of occupants (person), T_{zone} : Room temperature (°C), $T_{TES,top}$: Temperature of top layer of TES (°C), $T_{TES,bot}$: Temperature of bottom layer of TES (°C), $T_{c,in}$: Inlet temperature of chiller (°C), $T_{c,out}$: Outlet temperature of chiller (°C), \dot{m}_{pump} : Mass flow rate of pump (kg/s), $E_{chiller}$: Electric consumption of chiller (kWh), Superscript t : t timestep, Superscript $t + 1$: $t + 1$ timestep

MPCの問題設定

- ・制御目標：室内温度を冷房設定温度に維持 & 運用コストを最小化
- ・予測区間 (t_{Hp})：24 h
- ・制御間隔 (t_{Hc})：1 h
- ・制御変数：5台のポンプの流量値
- ・外乱の設定
 - 在室者発熱の変動
 - 変動型電気料金



- ・最適化手法：既往研究*で最適解探索に効率性が検討された、 ϵ DE-RJ (Epsilon constrained differential evolution with random jumping)を活用
 - メタヒューリスティクス手法の一類
 - 40個体100世代、合計4,000回の計算を行う

* S. Ikeda et al., Optimization method for multiple heat source operation including ground source heat pump considering dynamic variation in ground temperature, Applied Energy, vol. 193, pp. 466-478 (2017).

最適化問題

目的関数

ポンプの流量を最適制御することにより、チラーとポンプの合計運用コストを最小化する

$$\text{Minimize } J_S = \sum_{t=1}^{24} \left\{ \left(E_{\text{chiller}}^t + \sum_{n=1}^5 E_{\text{pumpn}}^t \right) \cdot P^t \right\} \quad (1)$$

24時間先までの合計運用コスト
電力消費量 電気価格

$$J_S = f(\dot{m}_{\text{pump1}}, \dot{m}_{\text{pump2}}, \dot{m}_{\text{pump3}}, \dot{m}_{\text{pump4}}, \dot{m}_{\text{pump5}}) \quad (2)$$

制御変数

制約条件

- ▷ 室内温度を冷房設定温度である26 °Cに維持
- ▷ ポンプの流量は、運転範囲内で制御
- ▷ ポンプの電力使用量は流量との線形関係式から求める

$$T_{\text{zone}} \leq 26 \text{ °C at } 09:00 \sim 18:00 \quad (3)$$

$$2.715 \text{ kg/s} \leq \dot{m}_{\text{pump1}}, \dot{m}_{\text{pump2}} \leq 10.86 \text{ kg/s} \quad (4)$$

$$2.055 \text{ kg/s} \leq \dot{m}_{\text{pump3}}, \dot{m}_{\text{pump4}}, \dot{m}_{\text{pump5}} \leq 8.22 \text{ kg/s}$$

$$E_{\text{pump}}^t \text{ (kWh)} = 0.2555 \cdot \dot{m}_{\text{pump}}^t \quad (5)$$

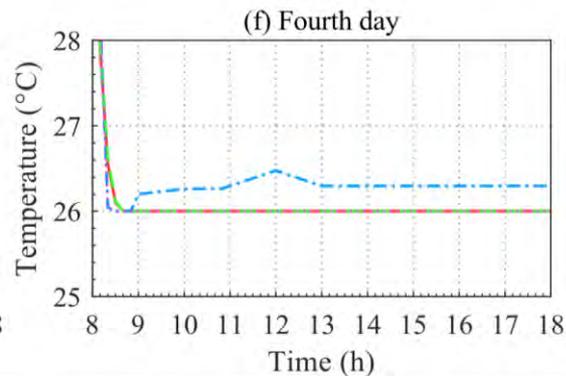
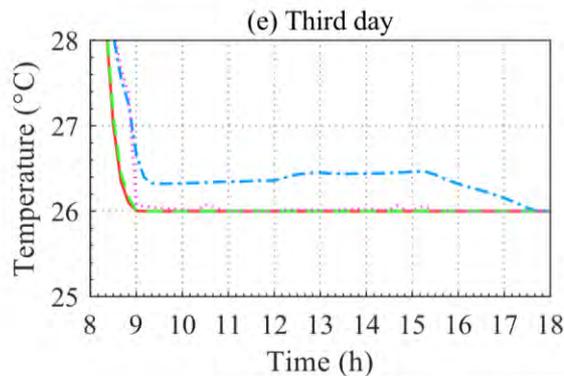
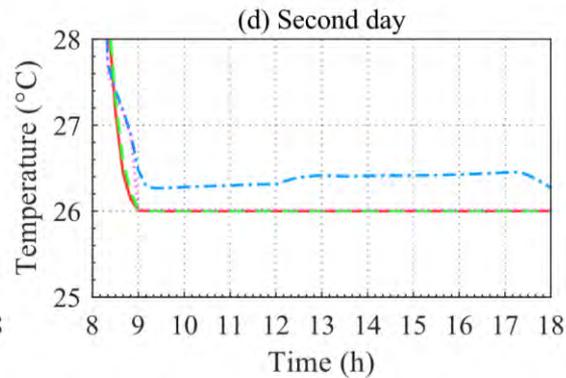
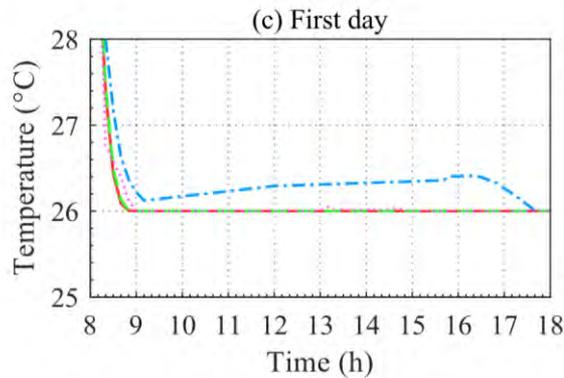
従来の制御手法

- MPCと比較する従来手法、Rule-based control (RBC)
 - ・ TES優先運転
 - ・ 蓄熱スケジュール：在室外時間帯、10.86 kg/s の一定流量で蓄熱
 - ・ 放熱スケジュール：在室時間帯、8.22 kg/s の一定流量で放熱
 - ・ 蓄熱量だけで室内負荷を賄うことができない場合、チラーが並列運転を開始
- ケースの分類
 - ・ 解析期間：4日間

	変動要素		制御手法	説明
	在室者	電気料金		
Case 1 (基準ケース)	×	×	RBC	外乱の変動を考慮しないRBC
Case 2 (RBC不適切運転)	○	×	RBC	在室者の変動を考慮したRBC ただし、Case 1 のポンプの流量で運転
Case 3 (RBC)	○	×	RBC	在室者変動を考慮したRBC
Case 4 (MPC)	○	○	MPC	在室者の変動・変動型電気料金を 全て考慮するMPC

結果：室内温度

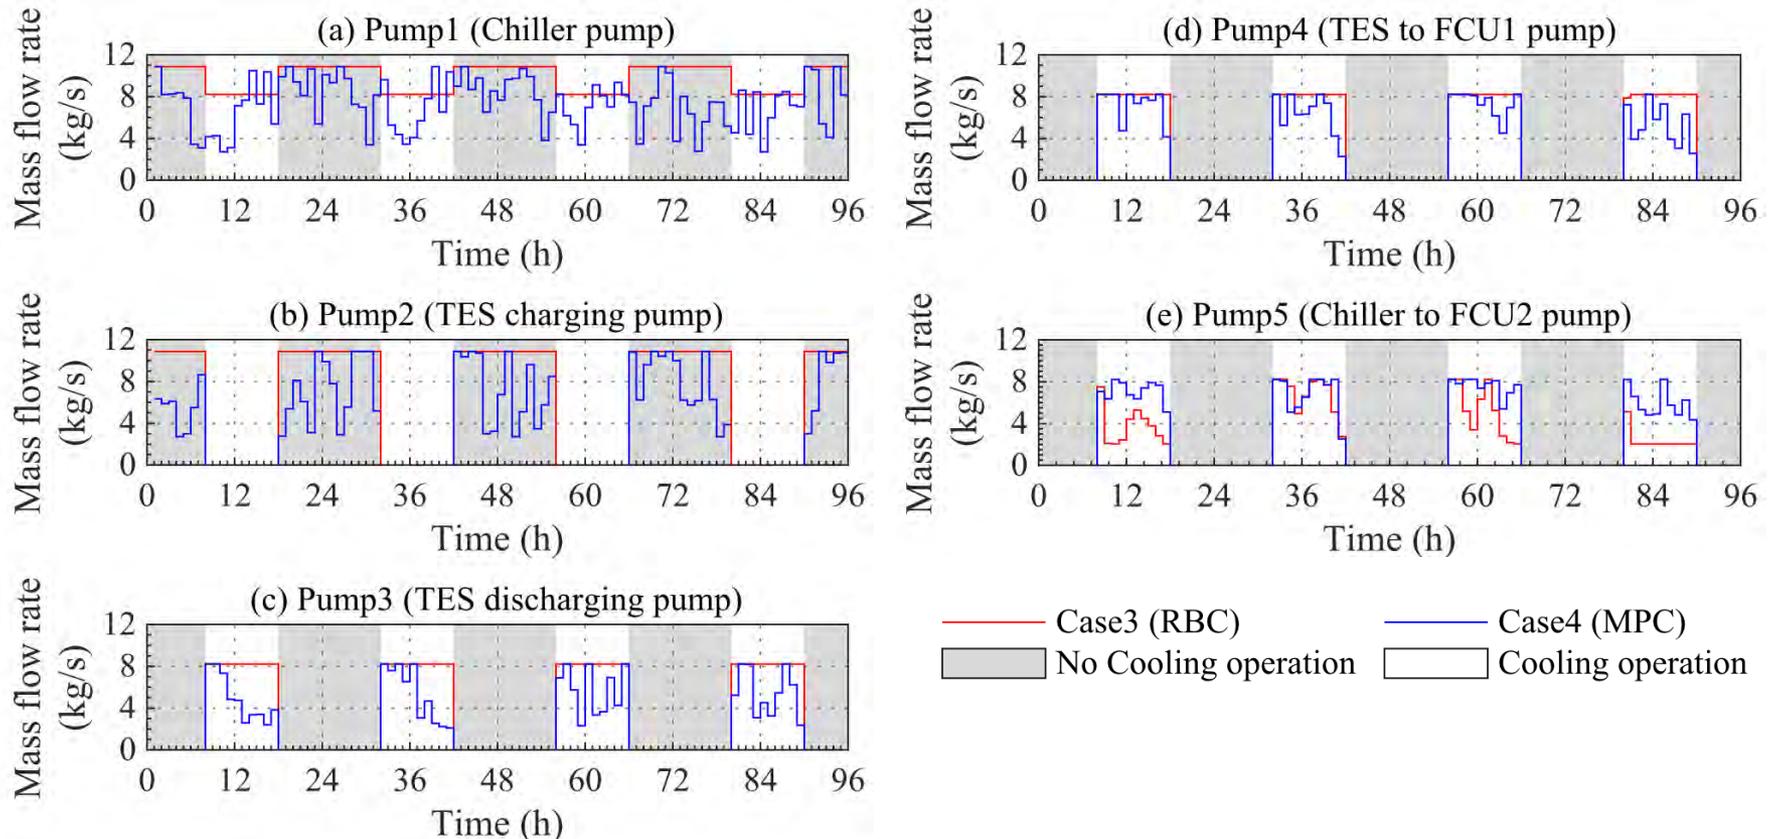
- ・ **Case 2**では、**Case 1**からのポンプの流量計画で運転されたため、室内温度が設定温度の**26 °C**に維持されていない。在室者が増加した反面**FCU**へ供給する流量が不足している。
- ・ **Case 2**を除く、全てのケースで室内温度が設定温度**26 °C**に維持されている。



- Case1 : 基準ケース
- · - Case2 : RBC不適切運転
- · - Case3 : RBC
- Case4 : MPC

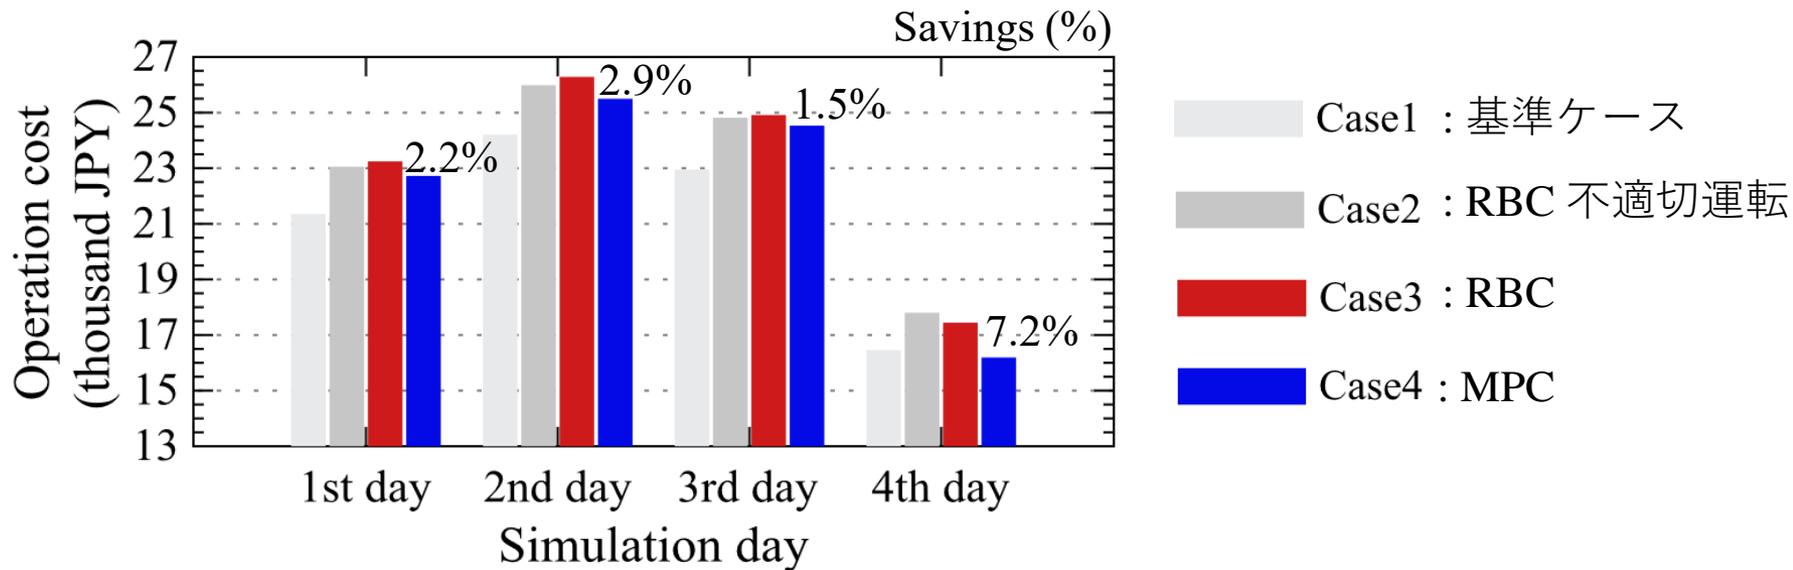
結果：ポンプの運転

- ・RBCのCase 3では、全てのポンプが一定流量で運転制御される。
- ・MPCのCase 4では、ANNの予測モデルに基づき1時間毎に24時間先までシステムの挙動を推定し、最適な流量を決定し、運転コストを最小限に抑える。



結果：運用コスト

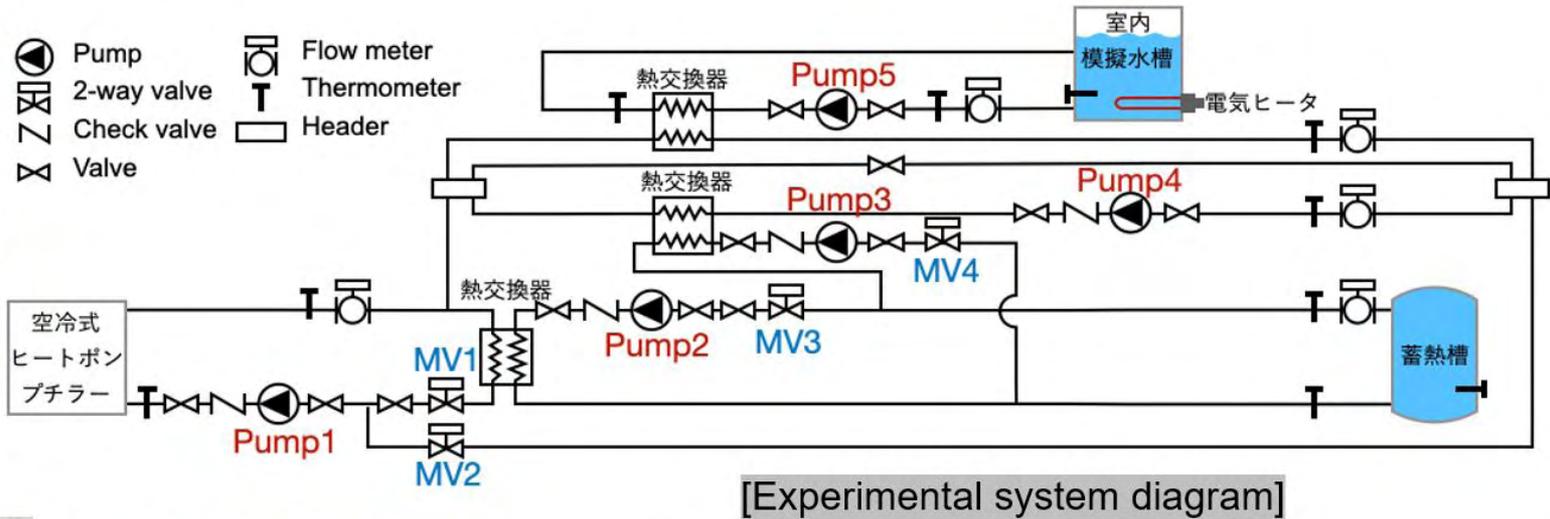
- 解析期間である4日間、MPCのCase 4の運用コストの積算値がRBCのCase 3より3.4%程度削減された。



MPCの実システムへの導入



[Measurement & Control by PC]



[Chiller]



[2-way valve]



[Pump]



[HEX]



[TES]



[模擬水槽&電気ヒータ]

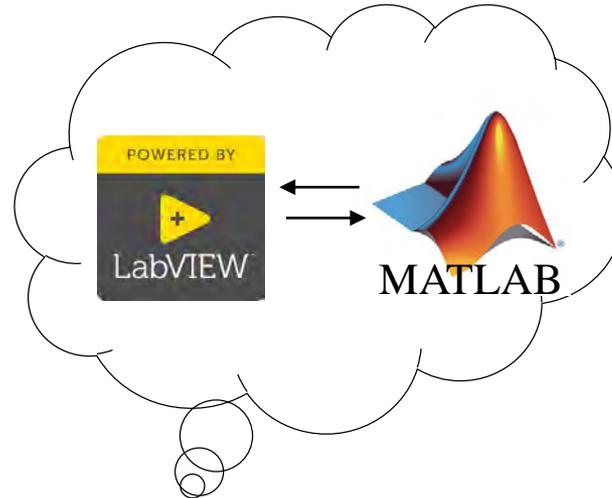
制御システム

計測



- ・ 温度
- ・ 湿度
- ・ 流量
- ・ 電力量
- ・ 機器ON/OFF状態

MPC演算



計測



制御



制御

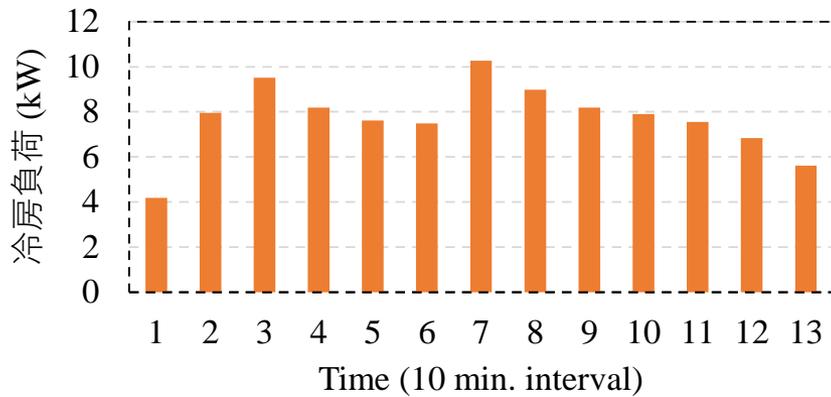


- ・ 流量値指示
- ・ 機器ON/OFF状態
- ・ バルブOPEN/CLOSE
- ・ チラー送水温度指示

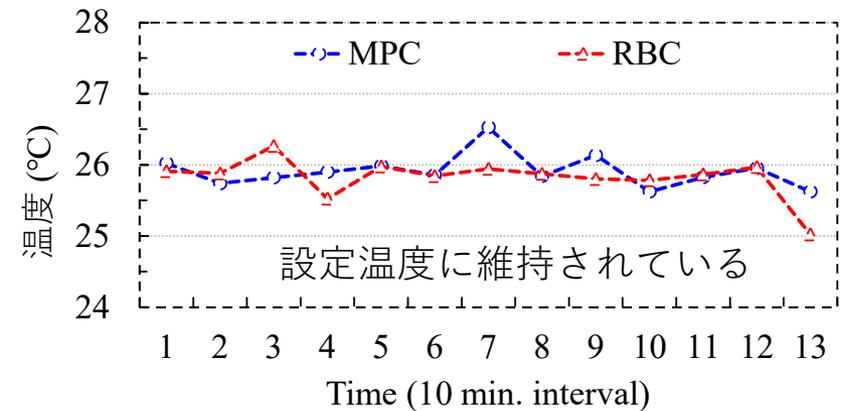
実験結果

- 当研究で構築したMPCを実システムへ導入し、6倍速の加速実験を実装

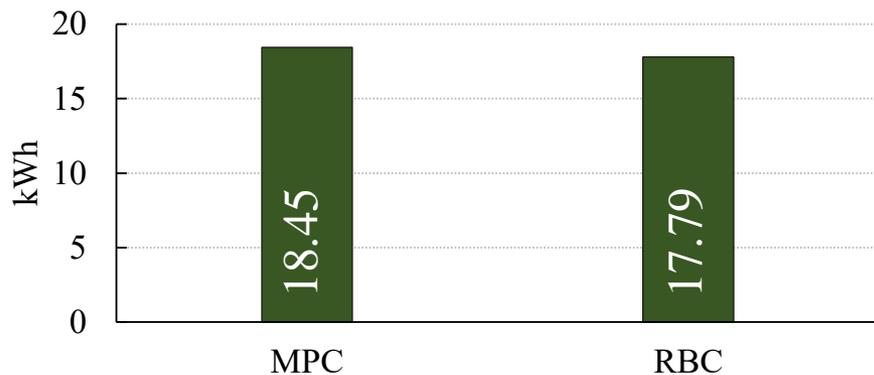
冷房負荷



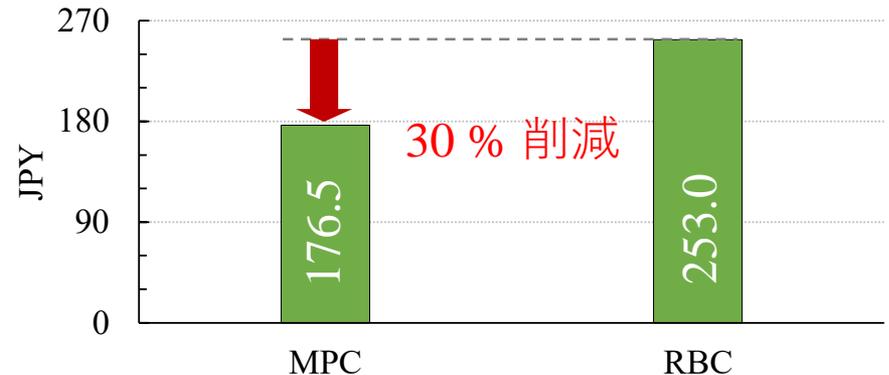
室内模擬水槽の制御結果 (設定温度26°C)



2次側での除去熱量(積算値)



運用コスト



ご清聴ありがとうございました