



Title	機械学習を用いたサーバールームにおける施設管理手法に関する研究
Author(s)	笹倉, 康佑
Degree Grantor	北海道大学
Degree Name	博士(工学)
Dissertation Number	乙第7122号
Issue Date	2021-03-25
DOI	https://doi.org/10.14943/doctoral.r7122
Doc URL	https://hdl.handle.net/2115/81317
Type	doctoral thesis
File Information	Kosuke_Sasakura.pdf



博 士 論 文

機械学習を用いたサーバールームにおける

施設管理手法に関する研究

Study on operation and management considering temperature
environment and energy in server room

2021年2月

笹 倉 康 佑

Sasakura Kosuke

目 次

第 1 章 序論..... 1

1.1	研究背景(データセンタの動向)	1
1.1.1	データセンタの社会的役割.....	1
1.1.2	データセンタの消費電力に関する動向	2
1.1.3	データセンタの要素技術の動向.....	3
1.2	データセンタ運営における課題	6
1.2.1	データセンタにおける適正な温度管理	6
1.2.2	データセンタにおける省エネルギー化.....	7
1.3	本研究において取り組む課題	8
1.3.1	課題解決に期待される要素技術(統合管理技術・データの活用技術)	8
1.3.2	本研究で対象とする課題	9
1.4	既往の研究と本研究の位置づけ	10
1.4.1	サーバールームにおける室温予測の手法.....	10
1.4.2	省エネルギー施策を支援するベースライン策定手法	13
1.5	本論文の目的と構成.....	15
	本章における参考文献.....	18

第 2 章 空調機運転時における室温予測手法の研究 2 2

2.1	本章の背景と目的	22
2.2	検証対象及び検証データ.....	23
2.2.1	検証対象のルーム.....	23
2.2.2	検証ルームにおける設備情報	24
2.2.3	システム構成	25
2.2.4	検証データ.....	26
2.3	予測モデルの構築及び評価方法	27
2.4	空調機運転時における室温予測手法の精度評価.....	29
2.4.1	各手法の精度評価及び選定	29
2.4.2	状態空間モデルを用いた室温予測手法に関する追加検証.....	34
2.4.3	本章のまとめ	41
	本章における参考文献.....	42

第 3 章 空調機停止時における室温予測手法の研究 4 3

3.1	本章の背景と目的	43
3.2	検証対象及び検証データ.....	44
3.2.1	検証対象のルーム, 設備情報, システム構成	44
3.2.2	検証データ.....	45

3.3	予測モデルの構築及び評価方法	52
3.3.1	予測モデルの対象と運転条件	52
3.3.2	予測モデルの手法	54
3.3.3	予測モデルの構築	55
3.3.4	予測モデルの評価方法	56
3.4	空調機停止時における室温予測手法の精度評価	57
3.4.1	予測モデルの精度評価及び選定	57
3.4.2	説明変数及び学習データが精度へ及ぼす影響	63
3.5	本章のまとめ	69
	本章における参考文献	70

第4章 省エネ改善実行時におけるエネルギー基準算出手法の研究 71

4.1	本章の背景と目的	71
4.2	検証対象及び検証データ	73
4.2.1	検証対象のルーム, 設備情報, システム構成	73
4.2.2	検証データ	73
4.3	エネルギー基準算出モデルの構築及び評価指標	74
4.4	エネルギー基準算出モデルの精度評価	76
4.4.1	エネルギー基準算出モデルの精度評価及び手法の選定	76
4.4.2	説明変数及び学習データが精度へ及ぼす影響	80
4.4.3	異なるルームにおける本手法の適用性に関する考察	82
4.5	省エネルギー施策実施時における効果検証	85
4.5.1	効果検証の概要	85
4.5.2	ラック吸気温度予測モデル及びベースラインモデルの構築	86
4.5.3	本研究で提案する省エネルギー実施に関するプロセスの検証	88
4.5.4	過去データを使用した場合のベースラインモデルとの比較	92
4.6	本章のまとめ	93

第5章 結論 95

5.1	本研究のまとめ	95
5.2	今後の課題と展望	97

本論文に関連する論文及び講演論文 98

第1章 序論

1.1 研究背景（データセンタの動向）

1.1.1 データセンタの社会的役割

データセンタ(DC)は複数のサーバールームを収容するための施設であり、クラウド等のネットワークを活用したサービスを提供するサーバやネットワーク機器の Information and Communication Technology(ICT)装置を集中管理している。これらのサービスは、我々が社会生活する際に欠かせないものとなっており、DC が担う社会インフラとしての重要性は非常に高いものとなっている。日本における成長戦略においても、各分野における ICT 化の推進、Internet of Things(IoT)や Artificial Intelligence(AI)の利活用が挙げられている[1][2]。その他にも Digital Transformation(DX)、デジタルツイン、5Gといった技術トレンドに関するデータを管理するDCが担う役割は今後も益々高まることが予測され、継続的な運用が求められていくと考えられる。




図 1-1 世界のIoTデバイス数の推移と予測[1]




図 1-2 データセンタ市場における推移及び予測[1]

1.1.2 データセンタの消費電力に関する動向

社会生活を支える重要な役割を果たす DC の消費電力は非常に大きく、全世界の消費電量の約 1% を占めると推算され研究も報告されている[3]。また、DC における消費電力の内訳を図 1-3 に示す[4]。消費電力のうち約 40% が冷却に占める割合となっており、この冷却にかかわる消費電力の削減に関する取り組みが様々取り組まれている。DC における効率的なエネルギーの利用を評価する指標には、グリーングリッドが提唱する PUE (Power Usage Effectiveness: ファシリティ電力効率) をはじめとした幾つかの指標が存在する[5]。




図 1-3 DC における消費電力の内訳

表 1-1 DC におけるエネルギー利用を評価する指標の一例[5]

No	指標名	算出式
1	PUE (Power Usage Effectiveness)	$PUE = \text{DC の総消費エネルギー}[\text{kWh}] / \text{IT 機器の総消費エネルギー}[\text{kWh}]$
2	REF (Renewable Energy Factor)	$REF = \text{再生可能エネルギー}[\text{kWh}] / \text{DC の総消費エネルギー}[\text{kWh}]$
3	ITEU (IT Equipment Utilization)	$ITEU = \text{IT 機器の総消費エネルギー (実測)}[\text{kWh}] / \text{IT 機器の総定格消費エネルギー (定格)}[\text{kWh}]$

1.1.3 データセンタの要素技術の動向

一般的なサーバールームには、ラックに実装された ICT 装置が収容されており、これを稼働するために冷却装置(空調機)、電力装置が一体的に構成されている。前項で記載した冷却に関する消費電力削減等の DC における効率化等を目的に、様々な新規技術が導入されている。本項では、DC を構成する ICT 装置、冷却装置、電力装置の観点から、各技術に関する動向・導入技術の一例を記載する。

(1) ICT 装置

ICT 装置に関する技術革新は非常に速く、様々な技術が導入されてきている。本項では、DC において導入が進む以下二つの技術の概要を記載する。

(i) 仮想化技術

ICT 装置の仮想化技術とは、物理サーバ上に仮想サーバを構築する技術を意味する。本技術の導入は、リソースの有効活用・運用コストの削減・処理能力の変化や構成変更などの要求への迅速な対応が可能等といったメリットが存在する。なお、多くのサーバを管理する DC において、サーバの統合化が可能になる。この仮想化技術には、任意のサーバ上で実行させる機能も存在し、仮想サーバを適切に集約あるいは分散させることで、耐障害性や省エネルギー性に優れた運用が可能であるため、最適な運用方式の検討に取り組んでいる事例も存在する[6]。しかし、サーバの統合化が可能になる一方で、ICT 管理者は物理サーバ以上の台数の仮想サーバを管理する必要があり、複雑化した管理への対応が求められる。

(ii) 高発熱密度化

クラウドサービス、IoT、AI などの普及に合わせ、DC が取り扱うデータの量は爆発的に増加し続けている。これら日々増大する情報に対応するため、その処理を行う ICT 装置は高性能化及び高集積化が進行している。同様に、ラック内における ICT 装置の搭載状況についても、高密度に搭載する傾向になっており、ラックあたりの消費電力は今後も増加傾向にある[7]。ICT 装置やラックにおける高密度化はサーバールームの高発熱化と関係し、適正な温度管理が求められる DC において深刻な問題となっており、サーバールームの効果的な冷却方式に関する検討も各社で取り組まれている[8][9][10]。

(2) 冷却装置

冷却にかかわるエネルギーの効率化, また高発熱密度化した ICT 装置やラックに対応するために, 様々な冷却方式が DC に導入されている。空気により冷却を行う空冷方式, 水や冷媒を利用する間接式液冷方式(コールドプレートの利用等)・直接式液冷方式(液浸冷却等)の様々な冷却方式が存在する[11][12][13][14]。また, 空冷方式について, サーバルームへの空気の供給方法(パッケージ型エアコンの利用や外気の利用など)も様々である。また, 近年では, サーバルーム内における空気の供給方法も二重床下から冷気を供給する方法[15], 壁面から冷気を供給する方法[16], アイルコンテイメントの利用(ホットアイルキャッピング・コールドアイルキャッピング)[17][18]など空冷方式に限定した場合においても選択肢は多様化している。

また, 前述した高発熱化した DC における効率的な冷却方式として液冷方式が存在する。冷媒の種類や熱交換方式などは様々な方法がある[19][20]。また, サーバを直接冷媒に浸ける液浸冷却などにおいても自然対流型・強制対流型など様々な選択肢も存在する[21][22]。このように DC における冷却方式は多様化, かつ ICT 装置との関係性も密接化している背景からも, DC の運用・維持管理が複雑化していることがわかる。

(3) 電力装置

(i) 高電圧直流給電

DC において、直流を電源とする ICT 装置は多く存在する。例えば、直流により動作する CPU は、商用電源から給電する際には交流から直流へ変換を行う。ここで、電圧を変換する際に電気回路の開閉によって電力の変換ロスが生じる。この変換ロスに対し、「高電圧直流給電(HVDC)」という技術が注目されている。HVDC は、高圧直流電流の使用により電力変換を最小限に抑え、従来の交流給電システムと比較し、給電効率が向上(省エネルギー化)するメリットがあげられる。また、その他にも、交流変換装置が不要となり、省スペース化・故障ポイントの削減による信頼性が高まるメリットも存在する[23][24]。

(ii) 再生可能エネルギーの利用

大量に電力を消費する DC において、再生可能エネルギーの利用が求められている。各社において、DC の電力消費における再生可能エネルギーの使用割合を拡大する働きがあり、「再生可能エネルギー100%」で運営する「ゼロエミッション・データセンター」の建設に関する発表なども存在する[25]。また、1.1.2 節で記載した通り REF といった指標が提唱されていることから、この再生可能エネルギーの利用促進に関する需要は今後も拡大することが予測されており、DC における電力消費は、省エネだけでなく創エネの観点も重要になることがわかる[5]。

1.2 データセンタ運営における課題

1.2.1 データセンタにおける適正な温度管理

前節で記載した通り、社会的に重要性を増している DC における運用には非常に高い信頼性が求められている。その一方で、1.1.3 項に記載した通り、DC には様々な技術が導入されており、複雑な環境における運用・管理が求められている。特に、DC 運用者と DC 利用者の間でラック吸気温度を一定以下に保つ **Service Level Agreement(SLA)**が締結されることが一般的であり、適切な温度管理への要求は高い。しかし、ICT 装置の仮想化技術や高発熱密度化が導入されたサーバールームにおける熱環境は、時間的にも空間的にも温度変動が大きくなることが予想され、適切な温度管理が非常に難くなる。適切に温度が管理されない場合、サーバールーム内における熱だまりの発生、その熱だまりを解消するために空調機の設定変更といった冷却に必要なエネルギーの増加が引き起こされる可能性がある。この一事例からもわかるように、今後も高発熱化が進むと予測されている DC において適正な温度は重要な課題となっている。

1.2.2 データセンタにおける省エネルギー化

1.1.2 項で記載した通り、DC における消費電力は非常に大きく、省エネルギー化は喫緊の課題である。そのため、DC の省エネルギー化について、1.1.3 項に記載した通り ICT 装置側・ファシリティ側(電力・冷却)の双方ともに技術開発が進められている。日本においても、DC における省エネルギー技術に関する研究開発は取り組まれており、各種報告がされている[24][25]。また、これら報告内において評価指標として用いられている PUE からわかるよう、DC の消費電力のうち約 40%を占める冷却に関わる消費電力に関する省エネルギー化に注目が集まっている。




図 1-4 モジュール型データセンタ(省エネルギー化技術に関する研究開発一事例) [24]

1.3 本研究において取り組む課題

1.3.1 課題解決に期待される要素技術（統合管理技術・データの活用技術）

ICT 装置側・ファシリティ側の関係性が密接化したことにより、DC の運用・管理は従来の個別管理では非効率化・品質低下する問題(1.2.1 項で議論した適正な温度管理ができなくなる等)が引き起こる可能性がある。この問題に対し、DCの情報を一元的に管理する統合管理技術に注目が集まっている。また、統合管理の実現を支援するツール（Data Center Infrastructure Management(DCIM)）も各社において開発されている[26][27][28][29]。これらのツール等利用により統合管理を実現することで、ICT 管理者もファシリティ管理者もお互いの管理する情報を確認可能となり、DC の運用・管理に関する効率化が期待されている。しかしその一方で、統合管理したデータの活用事例の多くは、「見える化」に留まっており、統合管理に期待される DC の運用・管理の効率化・品質向上に貢献するデータの分析事例は多く存在しない。そのため、統合管理の重要性や考え方は浸透されつつあるが、見える化以上の効果を確認した事例が多くないため導入が進んでいないという現状である。




図 1-5 個別管理と DCIM を用いた統合管理に関する概要

1.3.2 本研究で対象とする課題

本研究では、DC の統合管理したデータを活用することにより、前節で記載した DC の課題である①適正な温度管理、②省エネルギー化に対して以下の取り組みを行う。

適正な温度管理について、大きく二つの取り組みを行う。一つは、DC のサーバールームを対象とし、空調機が運転している状態において負荷等が変化した際の室温環境の変化を予測する手法の確立である。もう一つは、空調機が停止した状態における室温環境の変化を予測する技術である。特に後者は、空調機停止に伴い急激に温度上昇が起こる可能性があるため、継続的な運用を求められる DC において、空調機の故障や点検時における温度リスクを評価することは非常に意義がある。

次に、省エネルギー化について、省エネ改善実行時におけるエネルギー基準算出手法の確立に関する研究に取り組む。これは、高い信頼性が求められる DC において、省エネルギー施策を実施・推進する場合には、施策の策定後におけるリスク評価、施策の実施後における効果の把握も施策の策定と同様に重要であると考え。これは、信頼性を低下させるリスクや施策による効果を定量的に把握できない場合、DC 運用者や管理者の省エネルギー化に対するモチベーションが低下し、施策が実施されない、または継続されてない可能性が高くなるためである。そのため、省エネルギー化の実現には、省エネルギー技術の開発・導入だけでなく、省エネルギー効果を正確に把握するためのエネルギー基準算出手法の確立が重要な課題と考え、本研究において取り組む課題と設定した。

1.4 既往の研究と本研究の位置づけ

1.4.1 サーバルームにおける室温予測の手法

サーバルームにおける室温を予測する手法は様々な研究がされてきており、いくつかのアプローチが存在する。熱収支式等を用いた物理式、熱流体シミュレーションツール (Computer Fluid Dynamics simulation tool(以降, CFD と略す))を利用するアプローチなどがあげられる。その他にも実験に基づく近似式を作成するアプローチが存在する。

(1) 空調機運転時におけるサーバルーム内の室温予測手法

空調機運転時におけるサーバルーム内の室温を予測する手法に関する研究は、様々されてきている。特に、CFD を用いたサーバルームの室温環境の予測が代表的である。黄ら[30]、Betsegaw ら[31]は、外気導入型のサーバルームにおける冷却効果を検証するために、CFD を用いた検証を行い外気導入型による効果を確認した。また、諏訪[32]は、サーバルームにおける様々な空調方式について、CFD を用いて各方式による換気性能や冷却性能に関する比較検討を行った。研究における条件下において、天井吹出し・天井吸込みの採用が有意であると結論付けた。また、John ら[33]、Sami ら[34]、Emelie ら[35]はサーバルームの気流方式におけるアイルコンテイメントの効果を確認することを目的に、CFD を用いた検証を行い、各研究条件下におけるアイルコンテイメントにおける有効性を示した。これらの研究からわかるように、モデルの構築、境界条件を設定することで、室内環境の算出が可能であり、CFD は DC の効率的な設計・構築に貢献可能と考えることができる。更に、近年では冷却側だけでなく、ICT 装置側の変化も含めた研究が取り組まれている。境野[36]は、サーバルームにおける ICT 装置の負荷変動に対し空調機設定を変動・最適化するモデルを提唱し、CFD を用いて温度環境の評価を実施した。山崎ら[37]は、ICT 装置の負荷を内部発熱とし CFD にリアルタイムで情報を取り込むことにより、室内環境を従来と比較して高精度に予測可能なことを示した。また、梯ら[38]は ICT 装置の P-Q 特性を CFD に取り込むことにより実験同様の結果を得られることを明らかにし、この結果を用いサーバルームにおける換気方式の設計に関する検討を加えた。これら研究からわかるように、ICT 装置側とファシリティ側の関係性が密接化したことにより、ICT 装置側の情報を CFD に活用することで、より現状に近い室温環境の予測が実現可能なことがわかる。しかしその一方で、多数存在するサーバルームを対象とした場合、モデルの構築及び境界条件の設定に要する時間が膨大になることが推察される。また、精度向上の観点において、各モデル単位にチューニングが発生する可能性がある点、3次元の計算を行う場合には非常に計算コストが大きくなる点などのデメリットも存在する。

また、CFD 以外のアプローチとして、中尾ら[39,40]は、高発熱機械室における機器冷却特性について集中定数モデルを作成し、室温環境等の評価を行っている。このモデルは、室内に設置さ

れる機器からの再循環比を定義し、熱平衡式からの各点の温度を求めている。また、羽山ら[41]は、本モデルを用い、ラック形状が空調用エネルギー消費量へ与える影響や室内及びラック内における再循環を考慮した機器モデルを提案し、ICT 装置の吸込み温度に影響する要因、機器の冷却特性が空調効率に与える影響を明らかにした。これらの研究より、DC で収集可能な情報よりモデルを構築し、ICT 装置の吸気温度を高精度に算出することが可能なことがわかる。

現在の DC における統合管理・サーバールームにおける IoT 化の推進といった背景や、既往の研究より、ファシリティ側だけでなく、ICT 装置における情報を含め統合管理するデータを活用し、ラック吸気温度を高精度、かつ自己学習により簡易にモデル構築が可能な予測手法の確立が必要と考える。

(2) 空調機停止時におけるサーバールーム内の室温予測手法

空調機停止時におけるサーバールーム内の室温を予測する手法は様々な研究が取り組まれている。空調機運転時と同様に CFD を用いたアプローチや物理式を用いたモデルなどが存在する。

Paul ら[42]、Jinkyun ら[43]は、空調機が停止した際の温度上昇に関する時系列変化を CFD により算出し、サーバールームにおける室温環境の評価を実施した。さらに、Liz [44]は、空調機が停止した際の温度上昇に関する時系列変化を CFD により算出し、その結果を DC における無停電電源装置やバッテリー等の電力に関する設計への活用や設備の適正化に関する可能性を示した。また、Emelie ら[45]、Doug ら[46]は、同様に CFD により算出した空調機停止時の温度変化を CFD により算出し、アイルコンテイメントや蓄熱層が室温環境へ及ぼす効果を評価し、冷却に関する設計への活用や設備の適正化に関する検討を行った。また、粕谷ら[47]は ICT 装置を模擬した発熱体を利用し、空調機停止時における ICT 装置の発熱量と温度上昇の関係性を評価した。これらの研究からもわかるように、DC 設計及び運用において CFD の活用は非常に有効であると考えられる。しかし、前述した通り、CFD のモデル構築、チューニング、計算に要する時間が大きいため、全てのサーバールームにおいて CFD による詳細な検討を実施することは非常に難しいというデメリットも存在する。

また、その他のアプローチとして、松島ら[48]、大島ら[49]は故障後の室温変化を指数関数 1 項で近似した関数で表し、各故障パターンにおける許容温度の超過確率を簡便に求める方法を提案している。また、これらの研究をもとに、羽山ら[50]は、発熱密度に分布が存在するサーバールームにおける空調機停止後における最高温度を算出するモデルを構築し、決定係数 0.9 以上の非常に高い精度での予測が可能なことを明らかにした。このように、DC で収集可能な情報より物理式等を用いたモデルを構築し、空調機停止時における室温変化を高精度に算出することが可能であれば、DC の運用時において非常に重要な情報となる。特に、高発熱密度化する DC では、空間的にも温度環境が著しく変化することが予測され、最高温度だけでなく全てのラックにおける吸気温度を予

測が可能であれば、DC 管理者にとって非常に有益な情報となると考える。

現在の DC における統合管理・サーバールームにおける IoT 化の推進といった背景や既往の研究より、ファシリティ側だけでなく、ICT 装置における情報を含めた統合管理するデータを活用し、空調機運転停止時における各ラック吸気温度を高精度、かつ自己学習により簡易にモデル構築が可能な手法の確立が必要と考える。

1.4.2 省エネルギー施策を支援するベースライン策定手法

省エネルギー施策は DC だけでなく、商業ビル・オフィスビル・工場など様々施設において推進されている。また、省エネルギー施策は自社施設の効率化だけでなく、ESCO 事業なども展開されており、エネルギー削減効果を算出する方法は、大きく 2 通りのアプローチ提唱されている[51][52]。一つは、過去の統計値である最大値・最小値・平均値をベースラインとして用い、省エネルギー施策の効果を算出するアプローチである。もう一つは、ベースラインを推定するモデル(エネルギーシミュレーションツール・物理モデルや統計モデルを用いた推定式)を作成して、省エネルギー施策の効果を算出するアプローチである。

Jian ら[53]は、サーバールームを対象とし、過去の最大値及び最小値を使用した推定モデルを構築し、冷却システムの年間消費電力の推定が可能なことを報告した。西川ら[54]は、博物館を対象とした省エネルギー施策を実施し、前年度の年間消費電力をベースラインとして比較を行い、省エネルギー施策の効果を評価した事例を報告した。このようにデータの蓄積がある場合、過去データにおける最大値・最小値・平均値等の統計値を基準値として使用することは、簡易にベースラインを算出可能であり、省エネルギー施策の効果を把握することも容易である。しかし、その一方で、DC のようにサーバールームの ICT 負荷が時間的に変動する可能性が高く、今後高発熱密度化などが進むといった背景の中、サーバールームにおいて過去の統計値である最大値・最小値・平均値をベースラインとして使用することは難しい可能性が高い。

また、葛ら[55]はエネルギーシミュレーションツール BEST を使用して、ベースライン推定を行っており、高い精度でエネルギー消費量の計算を実現している。また、川村ら[56]は、高層ビルオフィスに対し、eQuest をシミュレーションツールとして用いた際の省エネ施策の効果を報告している。また、運用条件を追加しベースライン値を補正する手法を提案し、対象の条件下における提案手法の有効性を示した。DC においても、河野ら[29]、境野[36]は CFD ツールを利用し、サーバールームにおける空調機に関する消費電力を計算している。しかし、前述したように BEST や CFD ツールといったシミュレーションツールは高い精度での結果を得ることは可能であるが、その一方でそれらの準備や計算に要する時間が大きいといったデメリットも存在するため、室温予測と同様に全てのサーバールームに適応することは現実的には難しいと考える。

井城ら[57]は、事務所建物を対象としたエネルギー消費原単位に関する推定について、月別のエネルギーに関する変動パターンより基本負荷と変動負荷を定義した。これらの基本負荷及び変動負荷を推定する手法として、延床面積や外気温度を説明変数とした単回帰式及び重回帰式を用いた。重回帰式を用いた場合、基本負荷や変動負荷いずれも約 0.5 程度の相関係数が得られ、回帰式の利用により一定の相関を有する推定が可能なことを示した。Massimiliano ら[58]は、商業

ビルにおける冷暖房に関わる消費電力を、外気温度、日射を説明変数とした回帰式により推定し、高い精度で求まることが報告されている。また、寺野ら[59]は、事務所建物を対象とし、物理モデル及び時系列モデルを用いてベースラインを推定し、二つのモデルについて比較・考察を行った。その結果、いずれのモデルを使用した場合も実用可能な精度であると結論付けている。更に、物理モデルと比較して、時系列モデルの方が予測精度の観点で優れているが、変動が起きた場合の対応が難しいといったデメリットがあると示しており、物理モデル及び時系列モデルを場合によって使い分ける必要性について見解を述べた。

省エネルギー施策を推進するための背景やこれらの既往の研究より、DCのサーバールームにおける省エネルギー施策の推進を支援することを目的としたベースラインモデルは、結果が定量的に把握可能なこと、ベースラインの算出結果が理解可能なこと(説明力が高い)、ベースラインが高精度なこと、かつ自己学習により簡易にモデル構築が可能な手法の確立が必要と考える。

1.5 本論文の目的と構成

近年、DC は社会生活において重要なインフラの一つとなった。今後もデータセンタに対する需要は高まっていくことが予測されており、継続的な運営がより一層求められている。また、データセンタにおける消費電力は、非常に大きく今後も増加し続けることが予測されている。その一方で、データセンタを構成する ICT 装置の仮想化技術・高発熱密度化や空調方式の多様化等により ICT とファシリティの関係性は密になり、ICT とファシリティを個別に管理する従来の管理方法では非効率な運用・管理となってしまう問題が生じている。そこで、ICT とファシリティを統合管理する手法に注目が集まっている。また、統合管理に期待される役割は、運用・管理の効率化だけでなく、情報の活用により DC の継続的な運営を実現するための信頼性の向上・データセンタの省エネルギー化にも期待されている。しかし、現状は情報の見える化が中心であり、信頼性や省エネルギー性に寄与する分析や活用事例は少ない。

本研究は DC の運用者及び保守者を対象とし、継続的な運営を支援することを目的とした、高品質なデータセンタサービスの提供を支援する温度環境の運用・管理手法及びシミュレーション手法、省エネルギー施策を継続的に実施するための効果の評価手法及びシミュレーション手法に関する知見を与えることを目指している。

第 1 章「序論」では、研究の背景と目的を述べ、関連する既往の研究について概説し、本研究の位置付けを示した。

第 2 章「空調機運転時における室温予測手法の研究」では、ICT 装置及び空調装置から取得可能な情報を説明変数と定義し、各説明変数が変化した場合の温度環境へ及ぼす影響を考慮したサーバールームの運用・管理手法の考察を行った。取得した情報と機械学習を組み合わせ、各説明変数を入力値とし、1 時点先の各ラック吸気温度を出力するシミュレーションモデルを構築した。構築したモデルに関する評価指標を定義し、機械学習の手法を複数比較検討しサーバールームにおける温度環境を管理するモデルとして適正な手法について提案した。また、機械学習と熱収支式を組み合わせることによる予測精度へ及ぼす影響について考察した。さらに、シミュレーションモデルの説明変数・学習頻度・学習期間が予測精度へ及ぼす影響に関する考察を加えた。

第 3 章「空調機停止時における室温予測手法の研究」では、サーバールームにおける空調機が停止した場合の温度環境を考慮したデータセンタの運用・管理手法の考察を行った。各種情報からシミュレーションに用いる説明変数及び学習データを定義し、機械学習を用いた空調機停止後における各ラック吸気温度の時系列変化を出力するシミュレーションモデルを構築した。また、シミュレーションモデルに関する説明変数、停止前の空調機運転台数、及び学習データに関する学習頻度や量が予測精度へ及ぼす影響について考察した。これらの結果、空調機停止後におけるラック

吸気温度の時系列変化を高い精度で予測可能なことを確認し、保守者が空調機の点検時や故障時における空調機停止時における温度環境へ及ぼす影響を事前に検討可能なことを示した。

第4章「省エネ改善実行時におけるエネルギー基準算出手法の研究」では、省エネルギー施策を実施する場合に必要な業務工程を定義し、省エネルギー施策を推進するためには施策の効果を定量的かつ正確に評価することが重要、かつ課題であることを考察した。そこでエネルギー管理を実施する運用者や保守者が省エネルギー施策の効果を定量的に把握するための基準値を算出するモデルを構築した。サーバルームの特性を加味して、省エネルギー施策を実施していない場合の消費電力推定値(ベースライン)を算出する機械学習を用いたモデルを提案した。特に、本モデルでは省エネルギー施策の実施者が算出された効果に対して納得感があることが重要と考え、モデルの説明力という観点を加え機械学習の手法を複数選定した。それら複数手法を対象に本問題において重要となると考え定義した評価指標により、比較検討を行った。また、一般的に用いられる過去の統計値を用いた基準値と提案するモデルを用いた基準値を比較し、提案したモデルの方が過去の統計値を利用した場合に比べて高精度に算出可能なことを確認した。さらに、省エネルギー施策を模擬した検証を行い、本モデルによる効果の見える化が可能なことを示した。

第5章「結論」では、本研究で得られた知見を総括し、今後の課題と展望について考察した。

本研究はデータセンタの運用者及び保守者を対象とし、継続的な運営を支援することを目的とした、高品質なデータセンタサービスの提供を支援する温度環境の運用・管理手法及びシミュレーション手法、省エネルギー施策を継続的に実施するための効果の評価手法及びシミュレーション手法に関する知見を得た。また、本提案する手法について、検証対象と異なる条件下におけるサーバルームへの適応性や、大量のサーバルームを対象とした際の学習データについて、計算コストを加味した最適化などは今後の課題であり、今後はこれら課題に取り組み、多くのDCの運営に貢献することを目指したい。また、本研究において提案する手法により、DCにおいて統合管理するデータの活用によりDCの運営を高品質化・効率化できる可能性を示した。今後もDCにおけるデータ活用に関する研究開発に努め、DCの統合管理・高品質なサービス提供・高効率なDC運営に貢献していきたいと考える。




図 論文の構成と流れ

本章における参考文献

- [1]総務省:令和元年版情報通信白書(PDF版)第4章ICT政策の動向,
<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r01/pdf/01honpen.pdf>
- [2]総務省:令和二年版情報通信白書(PDF版)情報通信白書令和2年版概要「令和2年「情報通信に関する現状報告」」,
<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r02/summary/summary01.pdf>
- [3]Koomey, Jonathan.: Growth In Data Center Electricity Use 2005 To 2010.” A Report By Analytical Press, Completed At The Request Of The New York Times 9 (2011): 161.
https://www.missioncriticalmagazine.com/ext/resources/MC/Home/Files/PDFs/Koomey_Data_Center.pdf
- [4] ニール・ラムセン: データセンタの データセンタの電力効率のモデル化, APC ホワイトペーパー #113, <https://www.sbbi.jp/img/WP113.pdf>
- [5] 社団法人電子情報技術産業協会 グリーン IT 推進室:新データセンタエネルギー効率評価指標 DPPE (Datacenter Performance per Energy) 測定ガイドライン (Ver2.05), グリーン IT 推進協議会,2012年3月3日, https://home.jeita.or.jp/greenit-pc/sd/pdf/dppe_j_Measurement_Guidelines.pdf
- [6] 中村暢達, 喜田弘司, 竹村俊徳, 藤山健一郎:大規模 VM 負荷予測・配置制御技術によるシンクライアント・データセンターのグリーン化, NEC 技報, 2009年9月25日.
- [7] ASHRAE TC 9.9.: Datacom Equipment Power Trends and Cooling Application Second Edition, American Society of Heating Refrigerating and Air-Conditioning Engineers Inc. Atlanta, GA, USA, 2012.
- [8] 石谷直樹, 植草常雄, 木下学:データセンターにおける高発熱密度サーバーラックと空調効率に関する研究, 第19回環境工学総合シンポジウム, 2009.19巻,p.432-435,2009年7月.
- [9] 宇田川陽介, 柳正秀, 関口圭輔, 町田勝美, 三野洋介:データセンタにおける高発熱ラックの冷却に関する検討, 空気調和衛生工学会大会梗概集, p. 1839-1842, 2012年7月
- [10]木幡悠士, 関口圭輔, 柳正秀, 宇田川陽介:データセンタにおける高発熱ラックの冷却に関する検討, 空気調和・衛生工学会大会学術講演論文集, p.193-196, 2013年9月.
- [11]植草常雄, 木下学, 藁谷至誠, 三宅弘朗:データセンターにおける空調気流の応用設計技術に関する研究(第1報)標準設計と応用設計, 空気調和・衛生工学会大会学術講演論文集, p.1235-1238, 2007年9月.
- [12] Khosrow, Ebrahimi., Gerard, F, Jones., Amy, S, Fleischer.:A review of data center cooling technology, operating conditions and the corresponding low-grade waste heat recovery opportunities, Renewable and Sustainable Energy Reviews, Volume 31, p. 622-638, March, 2014
- [13] NEC 千葉正樹, 坂本仁, 小路口暁, 稲葉賢一, 松永有仁, 吉川実:複数発熱体に対する各種冷却方式の優位性検証, 第27回エレクトロニクス実装学会春季講演大会, p.334-337. 2013年3月.
- [14] 相澤直樹, 柴田克彦, 池田昌弘:PUE=1.0x(補機動力 nearly ゼロ)のデータセンター用冷却システムの開発～汎用機器を用いた冷却システムの運転状況～, 空気調和・衛生工学会大会学術講演論文集, p85-88, 2017年9月.
- [15] 木下学, 羽山広文, 小松正佳:電算機室空調システムの研究 その9 パッケージ形空調機を用いた電算機室用空調の高効率化対策, 空気調和・衛生工学会学術講演会講演論文集, p173-176, 1997年8月.
- [16] 三野洋介, 柳正秀, 楯龍平, 津田晃宏, 松田千怜, 篠田拓也:データセンタの壁吹出し空調方式における空調風量が装置冷却に与える影響, 空気調和・衛生工学会大会学術講演論文集,

p477-480, 2016 年 9 月.

- [17] 西村隼, 三野洋介, 津田 晃宏: データセンタにおけるコールドアイルキャッピングとホットアイルキャッピングの比較実験, 空気調和・衛生工学会大会学術講演論文集, p145-148, 2017 年 9 月.
- [18] ジョン・ニーマン: ホットアイルコンテインメントとコールドアイルコンテインメントの比較, APC ホワイトペーパー#135, https://www.apc.com/jp/s/products/isx/APC_WP_No135_J_Final.pdf
- [19] Michael, J, Ellsworth., Gary, F, Goth., Randy, J, Zoodsma., Amilcar, Arvelo., Levi, A, Campbell., William, J, Anderl.: An Overview of the IBM Power 775 Supercomputer Water Cooling System, Journal of Electronic Packaging, June, 2012, <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.687.2169&rep=rep1&type=pdf>
- [20] 松永有仁, 稲葉賢一, 千葉正樹, 小路口暁, 吉川実: 自然循環方式多段熱交換器を利用したデータセンタ排熱輸送, 空気調和・衛生工学会大会学術講演論文集, p197-200, 2013 年 9 月.
- [21] Phillip, E, Tuma.: The Merits of Open Bath Immersion Cooling of Datacom Equipment, 26th IEEE SEMI-THERM Symposium, Feb, 2010.
- [22] Chin-Chi, Cheng., Po-Chun, Chang., Hsing-Chieh, L., Fu-I, Hsub.: Design of a single-phase immersion cooling system through experimental and numerical analysis, International Journal of Heat and Mass Transfer, volume 160, 120203, Oct, 2020.
- [23] 山下暢彦, 田中徹, 加藤潤, 櫻井敦, 岩戸健, 新宅幹雄, 高橋晶子, 浅木森孔貴, 花岡 直樹, 松盛裕明: 高電圧直流給電システム導入拡大に向けた取り組み NTT 技術ジャーナル, 2015 年 1 月, <https://www.ntt.co.jp/journal/1501/files/jn201501036.pdf>
- [24] 独立行政法人 新エネルギー・産業技術総合開発機構省エネルギー部, 「グリーンネットワーク・システム技術研究開発プロジェクト(グリーンITプロジェクト)」(事後評価)(2008 年～2015 年), グリーンネットワーク・システム技術研究開発プロジェクト 事後評価分科会, 2013 年 9 月 4 日, <https://www.nedo.go.jp/content/100548379.pdf>
- [25] 総務省: グリーンデータセンターのベストプラクティスの国際標準化, 報道資料, 2011 年 12 月, https://www.soumu.go.jp/menu_news/s-news/01ryutsu02_02000029.html
- [26] Demetriou, Dustin, W., Calder, Andrew.: Evolution of data center infrastructure management tools. ASHRAE journal, vol61, p52-56, June, 2019.
- [27] Brown, Kevin., Bouley, Dennis.: Classification of Data Center Infrastructure Management (DCIM) Tools, Schneider Electric White Paper; Schneider Electric's Data Center Science Center: Foxboro, MA, USA, 2014, <https://it-resource.schneider-electric.com/white-papers/wp-104-classification-of-data-center-infrastructure-management-dcim-tools>
- [28] Sasakura, Kosuke., Aoki, Takeshi., Watanabe, Takeshi.: Study on Data Center Optimal Management by utilizing Data Center Infrastructure Management. In Proceedings of the 2017 IEEE International Telecommunications Energy Conference (INTELEC), Broadbeach, QLD, Australia, 22–26 October 2017.
- [29] 河野正人, 笹倉康佑, 渡邊剛: データセンタの最適マネジメント手法に関する研究 第 1 報 DCIM の概念と効果について, 日本建築学会大会学術講演会梗概集, p.1501-1502, 2016 年 8 月
- [30] 黄正豊, 張偉榮: 自然冷媒を用いたデータセンタ冷却システムに関する研究 その 1 室内の CFD 解析と実測結果の比較, 空気調和・衛生工学会大会学術講演論文集, p.161-164, 2017 年 9 月.
- [31] Betsegaw, Gebrehiwot., Kushal, Aurangabadkar., Naveen, Kannan., Dereje, Agonafer., Deepak, Sivanandan.: CFD analysis of free cooling of modular data centers, 2012 28th Annual IEEE Semiconductor Thermal Measurement and Management Symposium (SEMI-THERM), May, 2012
- [32] 諏訪好英: データセンターにおける空調気流方式の効率化に関する研究, 日本建築学会環境系論

文集, 76 巻, 663 号, p.501-508, 2011 年 5 月.

- [33] John, Niemann., Kevin, Brown., Victor, Avelar.: Impact of Hot and Cold Aisle Containment on Data Center Temperature and Efficiency; Schneider Electric White Paper 135; Schneider Electric's Data Center Science Center, 2017.
- [34] Sami, A, Alkharabsheh., Bahgat, G, Sammakia., Saurabh, K, Shrivastava.: Experimentally Validated Computational Fluid Dynamics Model for a Data Center With Cold Aisle Containment, Journal of Electronic Packaging, 137(2), 021010, June, 2015,
- [35] Emelie, Wibron., Anna-Lena, Ljung., T, Staffan, Lundström.: Comparing Performance Metrics of Partial Aisle Containments in Hard Floor and Raised Floor Data Centers Using CFD, Energies, 12(8), 1473, April, 2019
- [36] Sakaino, H.: Local and global dimensional CFD simulations and analyses to optimize server-fin design for improved energy efficiency in data centers. In Proceedings of the Fourteenth Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems, May 2014.
- [37] 山崎篤史, 阪田升, 中谷博, 谷知剛, 野口 哲福嶋 克也: データセンターにおける高密度サーバの冷却技術に関する研究開発(第 4 報) 内部発熱型シミュレータの概要と実機試験, 空気調和・衛生工学会大会学術講演論文集, p.265-268, 2013 年 9 月.
- [38] 梯洋貴, 倉渕隆, 吉野一, 竹内仁哉, 李時桓, 井上洋輔, 松尾一哉: データセンターにおけるハイブリッド換気システムの省エネルギー効果に関する研究(第 4 報) 実機サーバの P-Q 特性を考慮した CFD によるプロトタイプモデルの適正化, 空気調和・衛生工学会大会学術講演論文集, p325-328, 2015 年 9 月.
- [39] 中尾正喜, 西岡真稔, 羽山広文, 松尾陽: 高発熱機器室用空調気流方式の研究 第 1 報 気流方式の比較と機器吸込み平均温度計算モデルの実験検討, 空気調和・衛生工学会論文集, 19 巻 54 号, p.77-89, 1994 年 2 月.
- [40] 中尾正喜, 西岡真稔, 羽山広文, 松尾陽: 高発熱機器室用空調気流方式の研究 第 2 報 温度差の垂直分布モデル, 空気調和・衛生工学会論文集, 19 巻 56 号, p.87-97, 1994 年 10 月.
- [41] 羽山広文, 降旗由紀, 森太郎, 絵内正道, 木下学: データセンターの機器冷却特性と空調効率に関する研究, 日本建築学会環境系論文集, 第 74 巻 640 号, p.721-728, 2009 年 6 月.
- [42] Paul, Lin., Simon, Zhang., Jim, VanGilder.: Data Center Temperature Rise during a Cooling System Outage, Schneider Electric White Paper #179, Schneider Electric's Data Center Science Center, 2013, http://52.2.195.45/images/temperature_rise_cooling_outage.pdf
- [43] Jinkyun, Cho., Beungyong, Park., Yongdae, Jeong.: Thermal performance evaluation of a data center cooling system under fault conditions, Energies, 12, 2019
- [44] Liz Marshall, Transient CRAC Failure Analysis, Applied Math Modeling White Paper, Dec, 2012, https://coolsimsoftware.com/portals/0/pdf/wp_106_crac_failure.pdf
- [45] Emelie, Wibron., Anna-Lena, Ljung., T, Staffan, Lundström.: Comparing Performance Metrics of Partial Aisle Containments in Hard Floor and Raised Floor Data Centers Using CFD, Energies, 12(8), 1473, 2019,
- [46] Doug, Garday., Jens, Housley.: Thermal Storage System Provides Emergency Data Center Cooling, Intel Corporation White paper, 2007, <https://www.intel.com/content/dam/doc/white-paper/intel-it-thermal-storage-system-provides-emergency-data-center-cooling-paper.pdf>
- [47] 粕谷敦, 岩田徹也, 高橋智浩, , 和田一樹, 田中規敏, 山本順也: データセンターにおける床吹出空調方式の性能評価(第 2 報) 空調機の部分停止時における CFD 解析とサーバー模擬負荷実験

による評価, 空気調和・衛生工学会大会学術講演論文集, p37-40, 2014 年 9 月.

- [48] 松島修, 来永徹夫, 大島一夫: 通信機械室における空調装置の信頼度設計法の検討, 空気調和・衛生工学会学術講演会論文集, p.553-556, 1984 年 10 月.
- [49] 大島一夫, 実川博史: 通信装置用空調システムの信頼度の検討, p.197-200, 空気調和・衛生工学会学術講演会論文集, 1989 年 10 月.
- [50] 羽山広文, 木下学, 倉渕隆, 絵内正道: 空調機停止後の発熱分布を考慮した室温上昇に関する研究, 日本建築学会計画系論文集, 66 巻, 543 号, p.41-47, 2001 年 5 月
- [51] 村越千春, 渡辺俊行, 赤司泰義, 中上英俊: 我が国における ESCO 事業の特性に関する研究, 日本建築学会環境系論文集, 第 73 巻 624 号, p.245-252, 2008 年 6 月.
- [52] 一般社団法人電子情報技術産業協会, 国際標準のエネルギー管理手法~EnPI 導入ガイド~実践編[ISO 引用版], 2015 年
- [53] Jian, Li., Jakub, Jurasz., Hailong, Li., Wen-Quan, Tao., Yuanyuan, Duan., Jinyue, Yan.: A new indicator for a fair comparison on the energy performance of data centers, Applied Energy, 276, 2020.
- [54] 西川雅弥, 熊谷雅彦, 野村太郎, 鳥居博恭, 大塚大輔: 博物館における ESCO 事業を活用した省エネルギー改修と性能検証の実証的検討, 空気調和・衛生工学会論文集, 44 巻 264 号, p. 55-62, 2019 年 3 月.
- [55] 葛隆生, 中村靖, 山口峻: 建築物総合エネルギーシミュレーションツールの検証と活用方法の検討, 空気調和・衛生工学会大会学術講演論文集, p117-120, 2013 年 9 月.
- [56] 川村聡宏, 川島実: 高層オフィスビルに導入した省エネルギー技術の効果に関する計測と検証, 日本建築学会技術報告集, 21 巻 49 号, p.1147-1151, 2015 年 10 月.
- [57] 井城依真, 須藤諭, 吉野博, 村上周三, 坊垣和明, 松縄堅, 亀谷茂樹, 高口洋人, 半澤久, 奥宮正哉, 浅野良晴, 下田吉之, 村川三郎, 依田浩敏: 事務所建物のエネルギー消費原単位の推定に関する研究, 日本建築学会環境系論文集, 77 巻 673 号, p. 203-211, 2012 年 3 月.
- [58] Massaimiliano, Manfren., Nenedetto, Nastasi.: Parametric Performance Analysis and Energy Model Calibration Workflow Integration A Scalable Approach for Building, Energies, 13(3), 621, 2020,
- [59] 寺野真明, 村上昌史, 十河知也, 下田吉之, 栗林春樹, 藤原ゆり, 鳴海大典, 水野稔: 建物ベースライン 消費量推定による既築ビルの省エネルギー効果評価手法の開発, 日本建築学会技術報告集, 10 巻 19 号, p. 203-208, 2014 年 6 月.

第2章 空調機運転時における室温予測手法の研究

2.1 本章の背景と目的

第一章で記述した通り、DC におけるサーバールームでは、ICT 装置側、ファシリティ側のいずれも新技術をはじめ様々な技術の導入により、運用・管理が非常に複雑な環境となっている。社会的に重要なインフラを担う DC では、このような環境の中においても、より高い信頼性が求められる。特に、DC 運用者と DC 利用者の間でラック吸気温度を一定以下に保つ Service Level Agreement(SLA) が締結されることが一般的であり、適切な温度管理への要求は高い[1]。しかし、前章で記載した新技術の導入等の影響により、空間的にも時間的にも熱環境が変化する複雑な場における適切な温度管理は、非常に難しい。適切に温度が管理されない場合、サーバールーム内における熱だまりの発生、その熱だまりを解消するために空調機の設定変更といった冷却に必要なエネルギーの増加が引き起こされる可能性がある。また、従来の DC では現状の温度はモニタリングしているが、サーバールームの環境変化(ラックや ICT 装置の増設や撤去等)に伴う将来の温度変化を把握することができず、ICT 装置の配置に関する事前検討が難しいという課題が存在する。このような課題に対し、サーバールーム内におけるラック吸気温度を高精度に予測、シミュレーションする技術が求められている。

前章で記述した通り、温度を予測する既往の研究において、いくつかのアプローチが存在する。一つは、代表点の温度等を計算する熱収支式の利用である。本技術で代表点等の温度を推定することは可能だが、各ラック単位といった多点の吸気温度を予測することが難しい。また、もう一つアプローチは、物理方程式を使用した熱流体シミュレーションの利用である。本アプローチでは、空間全体の温度を把握することが可能であるがサーバールームや境界条件毎に発生するモデリングや計算にかかる時間が膨大になるため、汎用的な展開が難しい。さらに、サーバールームの特性等の影響により、シミュレーション結果と実測が乖離することがしばしば見受けられ、モデル単位にチューニングが必要になる場合が多いといった問題も存在する。

そこで、本研究では高精度かつ各サーバールームに汎用的に展開が可能な自己学習を特長とする機械学習と熱収支式を組み合わせた温度予測モデルを提案する。本報では、予測モデルに使用する機械学習の各手法に関する特徴の把握及び手法の選定、一時点先(30 分先)の各ラック吸気温度に関する予測モデルの構築及び検証した結果、考察を報告する。

2.2 検証対象及び検証データ

2.2.1 検証対象のルーム

東京都にあるオフィスビルに存在する、サーバルーム A 及びサーバルーム B を検証対象とする(図 2-1)。各サーバルームに関する情報を表 2-1 に示す。




図 2-1 サーバルーム平面図(左図:サーバルーム A, 右図:サーバルーム B)

表 2-1 各サーバルームの概要情報

	サーバルーム A	サーバルーム B
床面積[m ²]	140	85
ラック数	26	22
空調機台数	2	2
タスク型空調機台数	2	0

2.2.2 検証ルームにおける設備情報

(1) 空調機情報

いずれのサーバルームも空調機は空冷パッケージ型空調機(インバータ駆動)が設置されている。また、それぞれの空調機の冷房能力(JIS 基準値)は、空調機 1,2 は 45kW, 空調機 3,4 は 40kW である。

(2) センサ情報

各サーバルームにおいて、温度センサをラック前面高さ 1.5m の位置に設置した。本研究では、この温度センサをラック吸気温度として定義する。以下図 2-2 に温度センサ設置イメージを記載する。




図 2-2 温度センサ設置イメージ

2.2.3 システム構成

サーバールームにおけるデータの収集を目的としたデータ収集システムを構築した。システム構成概要を図 2-3 に示す。本システムは、空調機コントローラ、ラックコンセント、温度センサを対象にデータを収集する。なお、データ収集の間隔は、いずれも 1 分間隔でデータ取得している。各種データは、UDP プロトコルによりデータ取得しているため、データ欠損が発生した場合は線形補完によって補うこととした。データ収集システムは、本研究で構築するラック吸気温度を予測するモデルを実行するサーバとも同様に接続されており、収集データを CSV 化し計算実行用のサーバに受け渡す仕組みとなっている。なお、本研究において使用するデータ種類については、次項で記載する。




図 2-3 システム構成図

2.2.4 検証データ

本章で用いるデータの種類は、サーバルーム A 及び B において収集する各ラックの消費電力、空調機の吹出温度・戻り温度・消費電力・冷房能力・効率、各ラックの吸気温度とした。各ラックの消費電力は、各ラックに設置された合計 89 個の ICT 装置への配電用コンセントより消費電力を取得・集計し使用した。また、空調機に関する情報は空調機と併せて設置されるコントローラより 5 つの情報を取得した。それぞれデータ収集システムにおいて 1 分間隔で収集・蓄積されている各データを、30 分間の平均値に加工したものを予測モデルの構築及び検証用データとして用いた。また、本章では表 2-2 に示す 3 つの期間のデータを用いて評価を行った。

表 2-2 検証データ期間

No	検証ルーム	期間
1	A	2016 年 4 月 1 日～2016 年 4 月 30 日
2	A	2017 年 5 月 1 日～2017 年 10 月 31 日
3	B	2018 年 1 月 1 日～2018 年 2 月 28 日

2.3 予測モデルの構築及び評価方法

(1) 予測モデルの構築

本章で取り組む各ラックの吸気温度予測について、目的変数を各ラックの吸気温度に設定し、ICT装置の消費電力や空調機の情報を説明変数と設定した。検証期間の前 n 日前までのデータを学習期間とした予測モデルを構築し、予測時点の 30 分先のラック吸気温度を予測対象とした。予測モデルに用いる手法は、表 2-3 に示す複数手法を候補とした。なお、手法(b),(c),(d),(e)は以下のようにパラメータを設定する。(b) サポートベクターマシーンについて、python の scikit-learn に実装されているライブラリ SVR を使用する。カーネルにはガウシアンカーネルを使用し、グリッドサーチ法を用いて $C=8$ 、 $\gamma=3$ 、 $\epsilon=0.01$ とパラメータを設定した。(c) ニューラルネットワークについて、python の scikit-learn に実装されているライブラリ MLP regressor を使用する。グリッドサーチ法を用いて隠れ層 1、ユニット数 100、バッチ数 100(ミニバッチ学習)、学習率 0.001、活性化関数 Relu、勾配配下法 adam、L2 正則化を設定し、上記以外のパラメータについてはライブラリのデフォルト値を使用する。(d) Gradient boosting decision tree について、python を scikit-learn に実装されているライブラリ xgboost を使用する。グリッドサーチ法を用いて学習率 0.1、葉の追加による損失減少の下限 0、木の深さの最大値 3、ランダムに抽出される標本(データ)の割合 1、各決定木においてランダムに抽出される列の割合 1 を設定し、上記以外のパラメータについてはライブラリのデフォルト値を使用する。なお、No1 以外の期間においてもグリッドサーチ法により適正化したパラメータは同様の方法で適正化を行う。(e)状態空間モデルについて、本研究では、python のライブラリ statsmodels を使用する。モンテカルロフィルタ及び擬似ニュートン法を用いてパラメータ推定を実施する。

次に No1 の期間の評価結果より手法を絞り込み、No2 の期間で再度検証し詳細な評価を加えて、サーバルームの温度予測に適した予測手法を選定する。最後に、No3 の期間において、予測モデルの汎用性評価を目的とした検証を No2 の期間で選定した手法を用いて行う。

表 2-3 検証データ期間

No	手法
(a)	線形回帰(LM)
(b)	サポートベクターマシーン(SVM)
(c)	ニューラルネットワーク(NN)
(d)	Gradient boosting decision tree (GBDT)
(e)	状態空間モデル(SS)

(2) 評価方法

予測モデルの精度評価は、ラック吸気温度の実測値と予測モデルより算出された予測値を比較して評価を行う。なお、本章では、一般的な統計や予測の精度評価で用いられる相関係数、平均二乗誤差(RMSE)に加え、サーバールームにおける吸気温度を予測する問題の特性より、正解率及びピーク誤差の二つの指標を定義し、合計 4 つの指標により精度評価を実施した。

(1)相関係数

実測値と予測値の相関係数を算出し、精度を評価する。

(2)平均二乗誤差(RMSE)

予測等評価の指標として一般的に用いられる RMSE により精度を評価する。

(3)正解率

予測モデルの信頼性について、全体的にどの程度あたっているかを定量的に評価することが重要と考え、データ総数に対し、実測値の $\pm 0.5^{\circ}\text{C}$ に予測値が入っている数の割合を正解率と定義し、精度を評価する。

(4)ピーク誤差

予測モデルの信頼性について、実測値と予測値が大きく外れることが問題と考えられる。特に、実測値が予測値を上回る場合が運用上のクリティカルな問題となると考え、実測値が予測値を上回った最大誤差をピーク誤差と定義し、精度を評価する。

2.4 空調機運転時における室温予測手法の精度評価

2.4.1 各手法の精度評価及び選定

(1) No1 期間における検証(各手法の精度評価及び特徴把握)

No1 期間における 2016 年 4 月第 4 週を検証期間とし、前 21 日を学習期間とした各手法を用いた予測モデルの構築及び精度評価を行った。表 2-4 に各手法を用いた際の評価値を示す。これらの値は、評価指標(1)~(3)は全ラックにおける評価値の平均、評価指標(4)は全ラックにおけるピーク誤差の最大値を使用した。この結果より、手法(d),(e)の手法を用いた予測モデルの評価値が他の結果に比べて全体的に良いことがわかる。その一方で、手法(b),(c)を用いた予測モデルの評価値は低い。これは、2016 年 4 月第 4 週において、ICT 装置が増設されており、(b),(c)における予測はその時点より大きく外れた結果が観察された。これは外挿への対応ができていないことが原因と考えることができる。これらの結果より、No2 期間において、検証する手法を(d),(e)の二手法に絞り込んだ。

表 2-4 No1 期間における各手法の各評価指標値(N=40,320)

No	手法	評価指標			
		(1)	(2)	(3)	(4)
(a)	LM	0.58	0.36	0.86	0.97
(b)	SVM	0.19	0.46	0.78	1.54
(c)	NN	0.14	1.43	0.75	3.58
(d)	GBDT	<u>0.90</u>	<u>0.11</u>	<u>0.99</u>	<u>1.07</u>
(e)	SS	<u>0.97</u>	<u>0.10</u>	<u>0.99</u>	<u>1.04</u>

(2) No2 期間における検証(手法(d)および手法(e)の精度評価及び特徴把握)

No1 の期間で絞り込んだ2手法について、図 2-4、図 2-5 及び表 2-5 に概要を示す[2][3]。また、No2 期間では、学習期間及び検証期間をそれぞれ 1 カ月間とし、検証対象月の前月のデータを学習期間として設定した(表 2-6)。ラック吸気温度の実測値と各予測モデルを用いた際の予測値を比較した評価値を表 2-7 に示す。評価指標(1)~(3)は全ラックにおける評価値の平均、評価指標(4)は全ラックにおける評価値の最大を使用し、各月の予測結果を集計した値である。この結果よりどちらの予測モデルを用いた場合でも、非常に高い評価値を示しており高い精度での予測が出来ていると考えられる。また、全期間において若干であるが SS の方が GBDT に比べて評価値が高い結果が観察された。

次に温度の実測値と予測値の時間変化より、GBDT と SS の 2 手法の本研究目的に対する精度について更なる検討を加える。1 カ月間(2017 年 7 月)における A1 ラックに対するラック吸気温度の実測値と各予測モデルを用いて予測値の時系列変化をそれぞれ図 2-6,図 2-7 に示す。これら図よりわかるように、実測値の時系列変化に対して予測値が追従できていることがわかる。また、1 カ月間(2017 年 7 月)における A7 ラックに対するラック吸気温度の実測値と各予測モデルを用いて予測値の時系列変化をそれぞれ図 2-8、図 2-9 に示す。図 2-8 から予測時点(2017 年 7 月 5 日)において、実測値と GBDT を用いた予測モデルにおける予測値の誤差が大きくなったことがわかる。これは、この時点における A7 ラックの吸気温度が学習期間・検証期間において全ラックの中で最も低かったことが影響していると考えられ、GBDT では大きな変動が起こると予測が対応できず結果が悪くなると考えられる。一方で、図 2-8,図 2-9,表 2-7 に示すように GBDT に比べて高い評価値が得られた SS では、一時点前の結果を予測モデルに反映させ逐次的にモデル更新を実施しているため外挿への追従性が高く、良い結果が得られたと考えられる。




図 2-4 GBDT のイメージ[2]




図 2-5 状態空間モデルのイメージ[3]




図 2-6 A1 ラックにおける吸気温度の実測値と GBDT を用いた予測モデルによる予測値の比較




図 2-7 A1 ラックにおける吸気温度の実測値と SS を用いた予測モデルによる予測値の比較




図 2-8 A7 ラックにおける吸気温度の実測値と GBDT を用いた予測モデルによる予測値の比較




図 2-9 A7 ラックにおける吸気温度の実測値と SS を用いた予測モデルによる予測値の比較

表 2-5 各手法の特徴

No	手法	説明
(d)	GBDT	決定木を用いたアンサンブル学習で回帰・分類問題に用いられる予測手法
(e)	SS	時系列問題に用いられる予測手法

表 2-6 学習・評価期間の関係(期間 No2)

2017 年					
5 月	6 月	7 月	8 月	9 月	10 月
学習	評価				
	学習	評価			
		学習	評価		
			学習	評価	
				学習	評価

表 2-7 期間 No2 における各予測モデルの評価指標値(N=205,632)

No	手法	評価値			
		(1)	(2)	(3)	(4)
(d)	GBDT	0.82	0.35	0.62	2.77
(e)	SS	0.98	0.14	0.99	2.20

(3) 手法(e)に関する特徴(信頼区間の算出)

SS の特徴として、学習より信頼区間を用いた上下限値を算出可能である。本研究では、信頼区間 95%の上下限値を併せて算出した。図 2-10 に信頼区間を用いて予測値に関する上下限値を描画した温度の時系列変化を示す。図 2-10 からわかるように、予測上下限を用いることにより予測に対して実測値の誤差を小さく類推することができる。これらの結果より、時間的に温度環境が変化し高い信頼性を求められるサーバールームにおける予測では、追従性が高く、信頼区間を用いることにより予測結果の誤差を小さく考えることが可能な SS の方が適していると考ええる。次節以降では、SS を用いた予測モデルについて詳細な検討を加える。




図 2-10 A7 ラックにおける吸気温度の SS を用いた予測モデルの予測値及び上下限値

2.4.2 状態空間モデルを用いた室温予測手法に関する追加検証

2.4.2.1 熱収支式を組み合わせた際の精度評価

前節で高い精度で予測が可能と考えられた SS について、更なる精度向上に向けた検討を加える。精度向上を目的とし、熱収支式により算出する 30 分先の代表点温度を仮想代表点温度(Tref)と定義し、説明変数として加えた。熱収支式における周辺温度はサーバールーム A が隣接するルームで計測する代表点温度を 30 分で平均した温度を利用した。隣接するルームは、ロビーやオフィス等のサーバールームではないオフィス空間である。また、ルーム間における熱伝達率は自然対流を仮定し固定値を利用した。なお、サーバールームにおける ICT 装置発熱量は、隣接するルームとの間における熱伝達や熱伝導による熱の流入出と比較し、約 5-6 倍程度の大きさである。本熱収支式の計算におけるタイムステップは 0.5 秒間隔とした。

仮想代表点温度を加え、前節同様 No2 の期間について予測及び実測との比較による検証を行った結果を表 2-8 に示す。これら結果より、大幅な結果の向上は見られなかったが RMSE の値が約 10%小さくなっていることから熱収支式を組み合わせることによって、温度予測の精度が向上すると考えられる。

表 2-8 期間 No2 における SS モデルと Tref を説明変数に加えた予測モデル(SS+Tref)を用いた予測の各評価指標値(N=205,632)

No	手法	評価指標値			
		(i)	(ii)	(iii)	(iv)
(e)	SS	0.98	0.14	0.99	2.20
(f)	SS+Tref	0.98	<u>0.13</u>	0.99	<u>2.05</u>

$$T_{ref(n+1)} =$$

$$T_{ref(n)} + \Delta t / c_p \rho V \left\{ Q_{ict} + Q_{CRAC} + \sum_i^n h_i A_i (T_{ref(n)} - T_i) + \sum_i^n k_i A_i (T_{ref(n)} - T_i) / d_i \right\}$$

c_p : 空気比熱 [J/g・K]

ρ : 空気密度 [g/m³]

V : サーバルーム体積 [m³]

$\partial T / \partial t$: 温度時間変化 [T/s]

Q_{ict} : ICT 装置発熱量 [W]

Q_{crac} : 空調機冷房能力 [W]

h_i : 外壁における熱伝達率 [W/m²・K]

A_i : 外壁面積 [m²]

$T_{ref(n+1)}$: 仮想代表点の n+1 時温度 [K]

$T_{ref(n)}$: 仮想代表点の n 時温度 [K]

T_i : 外壁温度 [K]

k_i : 外壁における熱伝導率 [W/m・K]

d_i : 外壁厚み [m]

2.4.2.2 説明変数及び学習データが精度へ及ぼす影響

(1) 説明変数が及ぼす精度への影響

予測モデルを構築する際に、説明変数の選定は非常に重要である。それは、説明変数の選択が精度に対し影響を与えるだけでなく、データ収集システムに対する要求仕様や予測モデル構築に要する時間が大きく変化するためである。そこで本節では、予測モデルにおける各説明変数が精度に及ぼす影響を考察するために、説明変数を大きく二通り変化させた際の検証を実施した。一つは全ての説明変数より一つの説明変数を除いた場合、もう一つは一つの説明変数のみを説明変数とした場合の検証をそれぞれ実施した。No2 の期間において、説明変数の影響について、RMSE の値により評価を行っており、それらの結果を表 2-9、表 2-10 に示す。全ての説明変数のうち一つの変数のみを説明変数とした検証では、空調機戻り温度のみを説明変数とした場合が最も RMSE は良い値を示した。また、全ての説明変数より一つの説明変数を減らした場合、空調機戻り温度を説明変数より外した場合のみ RMSE の値が大きく低下していることがわかる。また、他の説明変数を減らした場合は RMSE の値にあまり変化が見られなかった。これらの結果より、空調機の戻り温度は精度に対する影響度が大きいと考えることができる。また、モデル構築に要する時間は、説明変数を変化させた場合においても大きな変化は見られなかった。これは本研究における説明変数自体が大量ではなく、変数の増減がモデル構築への影響が小さかったことが理由と考えられる。

表 2-9 No2 の期間における説明変数を一つのみ使用した場の RMSE の値(N=205,632)

除いた説明変数	RMSE
空調機の消費電力	0.22
空調機の COP	0.21
空調機の冷房能力	0.22
空調機の戻り温度	0.15
空調機の吹出温度	0.21
サーバールーム全体の消費電力	0.22
各ラックの消費電力	0.18
仮想代表点温度	0.22

表 2-10 No2 の期間における説明変数を一つ減らした場合の RMSE の値(N=205,632)

除いた説明変数	RMSE
空調機の消費電力	0.13
空調機の COP	0.13
空調機の冷房能力	0.13
空調機の戻り温度	0.18
空調機の吹出温度	0.13
サーバールーム全体の消費電力	0.13
各ラックの消費電力	0.14
仮想代表点温度	0.14
(参考)全ての説明変数を使用した場合	0.12

(2) 学習期間が及ぼす精度への影響

予測モデルを構築する際に、学習期間をどのような期間にするかを検討することは非常に重要である。それは、精度に及ぼす影響だけでなく、データ収集システムのサイジングや予測モデルの構築に関連する時間が大きく変化するためである。そこで、予測モデルにおける学習期間が精度に及ぼす影響を考察するために、No2 の期間における 1 カ月間(2017 年 8 月)のデータを用いて学習期間を変化させた検証を実施した。学習期間を変化させた際の精度への影響は、RMSE の値により評価を行っており、それらの結果を表 2-11 に示す。表 2-11 よりわかるように、学習期間を変化させることによって RMSE に大きな変化は観察されなかった。一方で、学習に要する時間は最大で約 2 倍程度増加したが、本研究のサーバールームのみを対象とした場合、運用上問題とならない時間であった。この結果より、予測モデルの構築において、1 週間程度のデータがあれば高い精度の予測が可能と考えられる。なお、高い精度を実現可能な最も短い学習期間の長さについては、今後の検討課題とした。

表 2-11 No2 の期間における学習期間を変化させた際の RMSE 値(N=41,644)

学習期間	評価期間	RMSE (SS +T _{ref} model)
評価期間前の 7 日間	2017 年 8 月	0.12
評価期間前の 14 日間		0.13
評価期間前の 21 日間		0.12
評価期間前の 31 日間		0.12
評価期間前の 61 日間		0.12
評価期間前の 92 日間		0.12

(3) 学習頻度が及ぼす精度への影響

予測モデルを構築する際に、学習頻度は予測モデルの精度と非常に密接な関係がある。そこで、予測モデルにおける学習頻度が精度に及ぼす影響を考察するために No2 の期間において学習期間を 1 か月間(2017 年 7 月)・評価期間を 1 か月間(2017 年 8 月)と固定し、学習頻度を变化させた予測モデルを構築し検証を実施した。表 2-12 に学習頻度を変更した際の RMSE の値を示す。表 2-12 より、学習頻度を短くした方が RMSE は小さい値になっていることがわかる。この結果より、本対象のサーバールームにおける温度予測において、直前の変動を学習させることが精度を向上に寄与すると考えられ、学習頻度を短くする方法が有効である。しかし、その一方で学習モデルの構築を短くすると構築毎に時間を要するため、運用や計算環境における適切な頻度を選定することが重要と考える。

表 2-12 No2 の期間における学習頻度を变化させた際の各 RMSE 値(N=41,644)

Case	予測モデルの更新頻度	計算回数	RMSE(SS +T _{ref} model)
Case1	1day	31	0.10
Case2	7days	4	0.11
Case3	14days	2	0.11
Case4	21days	2	0.11
Case5	31day	1	0.12

2.4.2.3 異なるルームにおける本予測手法の適用性に関する考察

本節では汎用化の検討をすることを目的に、サーバルーム B において SS(case6)と熱収支式を説明変数に加えた SS(case7)を用いた検証を実施した(表 2-13)。本節では, No3 の期間において学習期間を 1 カ月間(2018 年 1 月)とした予測モデルを構築し, 検証期間を 1 か月間(2018 年 2 月)とした。

Case6とCase7の結果より, どちらも同様に高精度の予測ができていると考えられる。また, 熱収支式を説明変数に追加した予測モデルの方が追加しない予測モデルに対して評価値が高いということがわかる。図 2-11 に Case7 における a1 ラックにおける吸気温度の実測値と予測値の時系列変化を示す。図 2-11 より, サーバルーム A と同様に実測値を予測値が追従できていることがわかる。これらの結果より, 本提案する熱収支式を説明変数として加えた SS を利用した予測モデルは, 同規模のサーバルームであれば学習によりそのサーバルームにあった予測モデルを構築し高い精度での予測が汎用的に可能と考えられる。

表 2-13 サーバルーム B における各予測モデルの評価指標値(N=37,632)

Case	Model	Evaluation index			
		(1)	(2)	(3)	(4)
Case6	SS	0.94	0.22	0.95	2.16
Case7	SS+T _{ref}	0.95	<u>0.19</u>	0.97	<u>1.91</u>




図 2-11 サーバルーム B の a1 ラックにおける吸気温度の実測値と SS+T_{ref} を用いた予測モデルによる
予測値の比較

2.4.3 本章のまとめ

本研究では、サーバルーム A におけるラック吸気温度を予測可能な予測モデルを構築し、評価を行った。予測手法として状態空間モデルを用いた予測モデルを構築し、熱収支式を説明変数として加えることにより高い精度で予測が可能であることを確認した。また、予測モデルの説明変数、学習期間、学習頻度のそれぞれが精度へ及ぼす影響を考察し、特徴を把握した。さらに、同規模の異なるサーバルーム B において、同予測手法を用いサーバルーム B のデータにおいて学習を行った予測モデルによる検証を行い、サーバルーム A と同様に高い精度での予測が可能であることを確認し、本予測モデルの汎用性を確認した。また、本章における今後の課題について、以下にまとめる。

- 本研究で対象とした2つの検証対象ルームと異なる条件下におけるルームへの適応性について検討が必要と考える。
 - 本検証ルームと比較して大規模なルームへの適応性
 - アイルキャッピングが設置されていないルームにおける適応性
 - 本検証ルームに設置される空調機は空冷式パッケージ型エアコンであるため、その他空冷方式への適応性
 - 冷気の供給方式について、本検証ルームと異なる方式に関する適応性
- 本研究では、学習期間 1 週間で高い精度を確認、学習頻度も短いほど精度が高くなる傾向があることを確認した。汎用的に本シミュレーションモデルを展開した場合に、計算コストが大きくなることが予測されるため、学習期間や学習頻度の最適化(どの程度まで短くできるのか、短くした場合の精度への影響)に関する検討が必要と考える。
- 本技術の対象であるサーバルームにおける温度逸脱の発生有無に関する確認について、今後設置が予測されている高発熱密度サーバ(10kW/Rack や 20kW/Rack)への対応について、検討することが重要と考える。

本章における参考文献

- [1] ASHRAE Thermal Guidelines: Energy Technologies Area, Berkeley Lab Home Page. Available online:https://datacenters.lbl.gov/sites/all/files/ASHRAE%20Thermal%20Guidelines_%20SVLG%202015.pdf (accessed on 29th June 2020)
- [2] Chen, T., Guestrin, C.: XGBoost: A scalable Tree Boosting Systems. San Francisco: ACM, 2016.08
- [3] Trevor, H., Robert, T., Jerome, F.: 統計的学習の基礎, (2014), p.385, 共立出版

第3章 空調機停止時における室温予測手法の研究

3.1 本章の背景と目的

第一章及び第二章の背景において記述した通り、高い信頼性が求められているDCの運用において、時間的にも空間的にも変化する環境における適切な温度管理は非常に難しい。特に空調機が停止した際の急激な温度上昇は、DCサービスの継続性に及ぼす影響が非常に大きい。この問題に対し、アイルコンテイメントやサーマルストレージの利用等の急激な温度上昇の抑制対策に関する必要があるほど、DCの運用において室温管理が重要なことがわかる。そのため、本章ではサーバールームにおける空調機停止時の室温変化(ラック吸気温度)を予測する技術に着目した。

1章で記述した通り、空調機停止時におけるサーバールームの温度変化を予測するアプローチとして、いくつかの手法が存在する。一つは、熱収支式を用いた代表点温度の計算である。このアプローチは代表点温度を計算可能だが、各ラックの吸気温度を計算することが難しいという問題がある。また、ほかの手法として非定常計算を実施するツールやCFDツールを使用するものがある。サーバールーム全体の温度をシミュレーション可能だが、モデリングや計算に要する時間が非常に大きくなるため、多くの部屋に適用することが難しいという問題がある。さらに、シミュレーション結果と実測値の乖離が存在することがしばしば起き、各モデル単位にチューニングも必要となる問題も存在する。

近年のICT装置の環境条件の緩和も進んでいるが、我々は既存フィールドのICT装置の環境条件を満足する室温環境の確保を目指し、より実環境に近いフィールドへの導入を目指して研究開発に取り組む[1]。本研究では、空調機停止後におけるラック吸気温度の時系列変化をサーバールームのデータと機械学習を使用して高精度かつ自己学習を特長とする予測モデルを提案する。本章では、あるサーバールームにおける事例研究として、モデルにおける精度検証の結果、学習データや説明変数がモデルへ及ぼす影響について考察した結果を報告する。

3.2 検証対象及び検証データ

3.2.1 検証対象のルーム，設備情報，システム構成

本章における検証対象のルームは，前章で記述したサーバルーム A とした(図 2-1)。ただし，空調機停止時により温度上昇が起こりやすいルームにおいて本予測技術の需要が高いと考え，サーバルーム A におけるアイルキャッピングは取り外して検証を行った。なお，キャッピングの有無を除き，前章と同様の設備，システム構成を検証に用いた。

3.2.2 検証データ

(1) 検証データの種類

データ取得システムが取得した情報のうち、各ラックの吸気温度、各ラックの消費電力、空調機の冷房能力の三つを検証用データとして用いた。なお、本章では 1 分間隔で取得したデータを加工せずに使用した。

学習用データ・検証用データの収集、及び予測モデルの構築・検証を行うことを目的とした、各空調機を運転させた状態から n 分間停止後、再度運転開始する実験を 2019 年 12 月 15 日～2020 年 2 月 28 日で実施した。空調機停止時間に関する検討を行うために、空調機の停止時間は 2 分間、5 分間、10 分間、20 分間と 4 パターンの実験を合計 60 回行った。各空調機の実験パターン数を表 3-1 に示す。なお、20 分の停止実験のパターン数には、室内温度の上限値を超えるパターンも存在しており、15 分程度で実験を停止したものも含む。

表 3-1 各空調機の停止に関する実験条件

停止条件	停止空調機	空調機停止時間			
		2 分	5 分	10 分	20 分
1 台→0 台	空調機 1	4 回	3 回	3 回	4 回
	空調機 2	4 回	2 回	4 回	5 回
2 台→1 台	空調機 1	1 回	2 回	3 回	7 回
	空調機 2	1 回	3 回	5 回	9 回

(2) 検証データの様相

本章で予測対象とする空調機停止後における室温変化を予測するため、各種データの振る舞いが通常の運用とは異なるため、以下に検証期間における各種データの様相について記載する。

(i) 空調機情報に関する基礎集計

実験を実施した期間における空調機の戻り温度に関する設定は 26℃に固定した。また、実験による空調機 1,2 の発停状態切り替え・戻り温度の設定温度・消費電力・吹き出し温度を図 3-1, 図 3-2, 図 3-3, 図 3-4 に示す。これらの図に示す挙動から、圧縮機が停止し送風状態になるサーモオフの影響を受けて、空調機設定温度に変更がない期間においても空調機の消費電力や吹き出し温度は定常的に変化している現状が観察された。




図 3-1 空調機の発停状態推移




図 3-2 空調機の戻り温度に関する設定温度推移




図 3-3 空調機の消費電力推移




図 3-4 空調機の吹き出し温度に関する推移

(ii) 各ラックの消費電力に関する基礎集計

ラック消費電力の大きさはラック毎に異なる。(図 3-5, 図 3-6) また、列単位に算出した各ラック間の相関係数も低く、トレンドについてもラック毎に異なることがわかった(表 3-2)。また、ラックに機器が搭載されていない、また搭載機器が運転されていないという理由から、一部のラックは使用されていないラックも存在する。




図 3-5 A1 ラックにおける消費電力推移




図 3-6 B1 ラックにおける消費電力推移

表 3-2 架列内のラック消費電力に関する相関係数の範囲

列	相関係数の範囲
A 列	0.01~0.32
B 列	0.01~0.37
C 列	0.01~0.42
D 列	0.01~0.27

(iii) 各ラック吸気温度に関する基礎集計

各ラックの吸気温度に関する時系列変化を図 3-7 に示す。各ラックの吸気温度に関する時系列変化は類似していることがわかる。また、ラック列における各ラックを比較した場合、ラック単位に温度の値は異なることがわかる。

また、空調機の吹出温度とラック吸気温度の差が大きいほど冷房能力の需要も大きく、空調機停止後におけるラック吸気温度に関する上昇の勾配も大きくなる。一例ではあるが、空調機の戻り温度の設定が 26°C の場合におけるラック吸気温度の実測値を 24°C 以上、24°C 未満に分類した温度の時系列変化を図 3-8 に示す。この図より、停止後における温度変化は停止時における温度によって異なることがわかった。また、停止時の温度が低い場合、高い場合に比べて温度上昇の勾配が大きいことがわかった。




図 3-7(a) A 列のラック吸気温度推移




図 3-7(b) B 列のラック吸気温度推移




図 3-7(c) C 列のラック吸気温度推移




図 3-7(d) D 列のラック吸気温度推移




図 3-8 停止時温度別の停止前後における温度推移

3.3 予測モデルの構築及び評価方法

3.3.1 予測モデルの対象と運転条件

本章では、対象サーバールームにおいて1台の空調機が運転している状態から急停止した場合、2台の空調機が運転している状態から1台が急停止した場合の2ケースについて、それぞれの停止した空調機が運転再開されるまでの各ラック吸気温度の時系列変化を予測対象とした。なお、空調機を停止した時間から再起動した時間までを予測するため、空調機の運転状態が切り替わる区間をブロックと定義し、各実験により生成されるブロックを学習データ及び評価に用いた。図3-9、図3-10に運転している空調機台数単位に各ブロックの生成方法に関する概要を示す。

予測間隔はデータ収集間隔と同様の1分間隔とし、空調機停止1分後～空調機運転再開までを予測する。なお、3.2.2項で記載した基礎集計結果より停止時のラック吸気温度により上昇の勾配が変化することがわかっている。その影響を受け、停止後のラック吸気温度の時系列変化を直接予測する際に、停止直後の予測が大きく外れる可能性がある。そのため、ラック停止時の温度から何度上昇するかを目的変数と設定した。




図 3-9 ブロックの概念図(空調機停止後の運転台数が 0 台のケース)




図 3-10 ブロックの概念図(空調機停止後の運転台数が 1 台のケースを含む)

3.3.2 予測モデルの手法

前章において検討した 1 次点先のラック吸気温度を予測するモデルには、GBDT と状態空間モデルを用い、一定の精度で予測が可能であることを確認している。その結果より、本研究においても、この2手法を候補として机上検討を行った。

時系列データの分析に多く用いられる状態空間モデルは、1 次点前の状態により逐次的にモデルを更新する特長を保有する。しかし、以下の点より空調機停止後の温度を予測するモデルに不適と考えた。

- ・予測結果を次の予測値に利用する(誤差を蓄積する)ため、精度が低下する可能性が高い
また、同様の理由より説明変数の考慮が難しい。
- ・基礎集計より、空調停止前後におけるラック吸気温度(目的変数)の関係性が確認できない。

これらの観点より、機械学習の 1 手法である Gradient Boosting Decision Tree(GBDT)を本章で取り扱う手法として選択した(図 2-4)。なお、説明変数は表 3-3 に示す変数を選定した。また、GBDT について、python を scikit-learn に実装されているライブラリ xgboost を使用する。モデルにおけるハイパーパラメータは、「葉の枚数」・「L2 正則化の重み」・「木の木数」についてグリッドサーチ法にて最適化する設定を用い、上記以外のパラメータはデフォルト値を用いた。

表 3-3 説明変数

No	説明変数
1	空調機停止後の経過時間
2	停止した空調機
3	ラック位置
4	停止 1 分前のラック吸気温度
5	停止 1 分前のラック総消費電力
6	停止 1 分前の空調機 1 冷房能力
7	停止 1 分前の空調機 2 冷房能力

3.3.3 予測モデルの構築

空調機停止後におけるラック吸気温度の時系列予測モデルとして、いくつかのアプローチを検討した(表 3-4)。No1 から No5 に番号が増えるにつれて、モデル粒度が細くなる。これは、各状況に合わせたモデル構築が可能になり精度が高くなることを期待した。しかし、その一方でモデル粒度を細かくすると1度の実験で得られるサンプルデータ数の減少や計算時間が増加するというデメリットも存在する。これら観点をふまえ、各モデルについて、次項で記載する評価指標に基づき精度比較を行った。

表 3-4 各モデルの概要

Model No	モデル名称	備考
1	統一モデル	全データを分類せずに一つの統一的なモデルを構築
2	空調機停止台数別モデル	空調機停止時間別にデータを分類し、空調機停止台数毎のモデルを構築
3	空調機別モデル	空調機毎にデータを分類し、空調機毎のモデルを構築
4	空調機停止台数別かつ、空調機別モデル	空調機停止時間・空調機毎にデータを分類し、モデルを構築
5	ラック別モデル	ラック毎にモデルを構築

3.3.4 予測モデルの評価方法

予測モデルの精度評価はラック吸気温度の実測値と予測モデルより算出された予測値を比較して評価を行う。本章の評価方法は、以下合計四つの指標により精度評価を実施した。

なお、同一ブロックにおける温度変化は類似している傾向が観察された。類似の傾向があるデータを様々な分割に割り振ると予測が簡易になり、正しく評価することができないと考えたため、1ブロックのサンプルはいずれの一つに割りふることにした。同様にデータセットに偏りがある場合、正しく評価ができないと考え、停止後の空調機台数・停止した空調機ごとのブロック数が均等になるように割り振り、交差検証を行った(表 3-5)。

(1)決定係数

本章では、既往の研究で用いられている決定係数を指標と設定した[2]。実測値と予測値の決定係数を算出し、精度を評価する。

(2)平均二乗誤差(RMSE)

予測等評価の指標として一般的に用いられる RMSE により精度を評価する。

(3)正解率

予測モデルの信頼性について、全体的にどの程度あたっているかを定量的に評価することが重要と考えた。そのため、データ総数に対し実測値の $\pm 0.5^{\circ}\text{C}$ に予測値が入っている数の割合を正解率と定義し、精度を評価する。

(4)ピーク誤差

予測モデルの信頼性について、実測値と予測値が大きく外れることが問題と考えられる。特に、実測値が予測値を上回る場合が運用上のクリティカルな問題となると考え、実測値が予測値を上回った最大誤差をピーク誤差と定義し、精度を評価する。

表 3-5 交差検証用データの内訳

停止後の空調機台数	停止空調機	分割 Group[ブロック数]				
		Group 1	Group 2	Group 3	Group 4	Group 5
0 台	空調機 1	3	3	3	4	3
	空調機 2	2	2	3	3	3
1 台	空調機 1	3	3	2	2	3
	空調機 2	4	4	4	3	3

3.4 空調機停止時における室温予測手法の精度評価

3.4.1 予測モデルの精度評価及び選定

(1) 全実験パターンを対象とした各モデルの精度評価

実験 60 パターンを対象とし、精度評価を行った際の各モデルの評価値を表 3-6 に示す。評価指標(1)~(3)について、全体的に同等かつ良い評価値を示していることがわかる。また、評価指標(4)のピーク誤差では、Model No1,No2と比較して Model No3~5 の評価値は悪い値を示しているように捉えられる。この結果から、Model No1,No2 が全体的に良い評価値を示しており、更に予測精度とモデル粒度の細かさとの関係性は大きくないと考えることができる。なお、各モデルに関する特徴を把握することを目的に、次節以降で詳細な検討を加える。

表 3-6 各モデルの評価指標値(全 60 パターン対象)

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	<u>0.91</u>	<u>0.50</u>	0.78	<u>2.07</u>
2	0.90	0.53	0.76	2.50
3	0.90	0.53	0.78	3.78
4	0.90	0.53	<u>0.79</u>	3.33
5	0.90	0.55	0.75	3.68

(2) 空調機停止後台数別の精度評価

全実験パターンにおいて検証した結果を空調機停止後台数別に分類した結果を表 3-7、表 3-8 に示す。空調機停止後 0 台の結果のみ抽出した場合の評価値は、全ての評価値で Model No1 が最も良い値を示した。その一方で、空調機停止後台数 1 台の結果のみ抽出した場合の評価値は、Model No1 は他の Model と比較してあまり良い値を示していないことがわかる。このように、Model No1 は空調機停止台数により評価値に差が出ることがわかった。また、Model No2~No4 は空調機停止台数による評価値の差が大きくないため、空調機停止台数の違いに対して頑健なモデルと考えられる。

表 3-7 空調機停止後台数 0 台の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	<u>0.97</u>	<u>0.30</u>	<u>0.90</u>	<u>2.06</u>
2	0.90	0.54	0.76	2.46
3	0.89	0.53	0.78	3.26
4	0.89	0.56	0.76	3.33
5	0.94	0.39	0.88	3.68

表 3-8 空調機停止後台数 1 台の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	0.80	0.57	0.71	<u>2.07</u>
2	<u>0.90</u>	0.53	0.76	2.48
3	<u>0.90</u>	0.54	0.78	3.78
4	<u>0.90</u>	<u>0.51</u>	<u>0.80</u>	2.87
5	0.79	0.60	0.69	2.71

(3) 停止空調機別の精度評価

全実験パターンにおいて検証した結果を停止した空調機別に分類した結果を表 3-9、表 3-10 に示す。Model No5 は、停止した空調機による評価値に差が生じていることがわかる。また、その他の Model では停止した空調機の違いにより評価値に差が小さいことがわかる。この結果より、Model No1~Model No4 は停止した空調機の違いに対して頑健なモデルと考えることができる。なお、Model No1, No2 は空調機による違いを考慮せずにモデルを構築している。この結果より、本検証サーバルームにおける検証では、空調機を識別したモデル構築は精度に大きな影響を与えないと捉えることができる。

表 3-9 空調機 1 を停止した際の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	0.93	0.54	0.75	1.90
2	0.89	0.55	0.77	2.46
3	0.90	0.54	0.79	3.26
4	0.89	0.54	0.79	3.33
5	0.93	0.54	0.75	2.66

表 3-10 空調機 2 を停止した際の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	0.90	0.41	0.82	2.07
2	0.91	0.52	0.75	2.48
3	0.89	0.54	0.78	3.78
4	0.90	0.52	0.78	3.15
5	0.86	0.49	0.78	3.68

(4) 停止時間別の精度評価

全実験パターンにおいて検証した結果を空調機停止後の経過時間別に分類(10 分未満, 10 分以上)した結果を表 3-11, 表 3-12 に示す。表 3-11 より, Model No1 は他の Model と比較して空調機停止後(10 分未満)の時系列変化を高い精度で予測可能なことがわかる。その一方で, 表 3-12 に示す通り, 10 分後以降の予測精度が低下することがわかる。Model No5 も同様に空調機停止後の時間により, 評価値に差が生じている。また, Model No2~No4 は空調機停止後の経過時間に対して評価値に大きな差が生じないことから, 頑健なモデルであると考えることができる。

表 3-11 停止時間が 10 分未満の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	0.97	0.31	0.90	1.53
2	0.91	0.53	0.78	2.46
3	0.89	0.54	0.78	3.78
4	0.90	0.54	0.79	3.33
5	0.96	0.35	0.87	2.25.

表 3-12 停止時間が 10 分以上の結果のみ抽出した評価指標値

Model No	評価指標			
	(1)	(2)	(3)	(4)
1	0.90	0.67	0.61	2.07
2	0.91	0.54	0.76	2.48
3	0.89	0.52	0.79	3.26
4	0.90	0.52	0.78	2.87
5	0.86	0.73	0.58	3.68

(5) 各モデルに対する総合評価

本項において、複数の観点で各モデルの精度評価を行った。これらの評価結果より、以下の2つの理由より Model No2 の空調機停止台数別にモデルを構築することが適切であると考ええる。

- ・全実験パターンを対象とした精度評価において、他のモデル同等に高い数値が観察された点
- ・空調機停止台数・空調機号機・空調機停止後経過時間に関する観点での精度評価において、安定して高い評価値が観察された点

Model No2 を使用した空調機停止後の C1, C3, C5, C7 ラックにおける実測値及び予測値の時系列変化を図 3-10, 図 3-11 に示す。図 3-10 よりわかるように運転停止後のラック吸気温度の時系列変化の相関を捉えて予測できていることが視覚的にわかる。また、図 3-11 より一部のラック吸気温度の予測値が実測値を約 1 度程度上回っているラックが存在するが大きな相関を捉えて予測ができていることが視覚的にわかる。

なお、次項以降は Model No2 に着目し、詳細な検討を加える。




図 3-10 空調機 1 運転停止後(停止後運転台数 0 台)における C 列ラックに関する吸気温度の実測値と
予測値の時系列変化




図 3-11 空調機 1 運転停止後(停止後運転台数 1 台)における C 列ラックに関する吸気温度の実測値と
予測値の時系列変化

3.4.2 説明変数及び学習データが精度へ及ぼす影響

(1) 説明変数が精度へ及ぼす影響

説明変数の適正化は精度向上の観点、計算コストの観点からも非常に重要である。そのため、本項では説明変数に関する詳細な検討を加える。

はじめに、各説明変数が精度へ及ぼす影響を考察するために、変数重要度を算出した。表 3-13 に停止後の空調機台数が1台の予測における各説明変数の変数重要度を示す。この表より、ラック位置・停止した1分前のラック吸気温度・空調機2の冷房能力などの説明変数が本検証ケースにおいて重要だということ、各説明変数により精度への影響度が異なることがわかった。

つぎに、各説明変数を変化させた際に精度への影響を考察するために、表 3-3 で示した説明変数の1つを削除した場合、説明変数を1つのみ使用した場合で同様の検証を実施した。

表 3-14 に説明変数の1つのみを使用した場合の精度評価値の一覧を示す。この結果より、説明変数を1つにした場合精度評価値はいずれの場合も低下している。さらに、停止1分前のラック吸気温度のみを使用した場合、他の説明変数のみを使用した場合と比較して、精度評価値は良い値を示していることがわかる。

表 3-15 に説明変数の1つを削除した場合の精度評価値の一覧を示す。この結果より、ラック吸気温度を除外した場合の評価値は、全ての説明変数を使用した場合と比較して全体的に低下している。また、その他の説明変数を除外した場合の評価値は、全ての説明変数を使用した場合と大きな差がないことがわかる。

これらの結果より、本対象ルームにおける空調機停止後のラック吸気温度予測精度について、1分前のラック吸気温度が非常に重要と考えられる。

表 3-13 各説明変数の変数重要度

No	説明変数	変数重要度
1	空調機停止後の経過時間	35.69
2	停止した空調機	5.38
3	ラック位置	18.91
4	停止 1 分前のラック吸気温度	15.79
5	停止 1 分前のラック消費電力	6.88
6	停止 1 分前の空調機 1 冷房能力	5.01
7	停止 1 分前の空調機 2 冷房能力	12.34

表 3-14 説明変数 1 つのみ使用した場合の評価指標

使用した説明変数	評価指標			
	1	2	3	4
停止 1 分前のラック吸気温度	0.88	0.59	0.90	3.28
停止 1 分前のラック消費電力	0.78	0.81	0.83	4.97
停止 1 分前の空調機 1 冷房能力	0.80	0.78	0.82	4.51
停止 1 分前の空調機 2 冷房能力	0.82	0.73	0.83	3.38
(参考) 全説明変数を使用	0.90	0.53	0.92	2.48

表 3-15 説明変数 1 つを除外した場合の評価指標

除外した説明変数	評価指標			
	1	2	3	4
停止 1 分前のラック吸気温度	0.83	0.72	0.85	4.38
停止 1 分前のラック消費電力	0.90	0.53	0.92	2.47
停止 1 分前の空調機 1 冷房能力	0.90	0.55	0.91	2.57
停止 1 分前の空調機 2 冷房能力	0.90	0.47	0.94	2.49
(参考) 全説明変数を使用	0.90	0.53	0.92	2.48

(2) 学習データが精度へ及ぼす影響

本モデルは教師有学習のため、学習データが必要となる。また、機械学習モデルを使用する場合、精度と学習データの質や量の関係性は非常に密接である。そのため、以下では、学習データに関する三つの観点における精度への影響を検証・考察する。

(i) 学習データのサンプル数が精度へ及ぼす影響

学習データのサンプル数が精度へ及ぼす影響を把握することによって、どの程度のサンプル数を収集する必要があるか検討が可能になる。精度への影響を考察するために、5 分割したデータセットの評価用データセット以外のデータセットの割合を変化させた場合、どのように精度評価値が変化するかを観察する。データセット数を減少させた場合の各精度評価値を表 3-16 に示す。この結果より、決定係数・正解率・RMSE の値はデータセット数が減少するほど、悪い値となることがわかる。また、データセット数が 0.4 程度あれば決定係数が 0.8 以上を示しており、高い精度で予測できたと考えられる。その一方でデータセット数を 0.2 に減少させた場合、決定係数が 0.8 未満となり、予測精度が高くない結果と考える。正解率や RMSE についてもデータセット数が 0.2 になった場合、著しく値が低下する結果が観察された。これら結果より、本検証ルームでは、評価データのサンプル数に対して、40%のデータセットがあれば高い精度の予測が観察された。しかし、データセット数が多いほど精度が高い結果が得られたため、可能な場合は評価データと同等のサンプル数を用意したほうが良いと考える。

表 3-16 データセット数が精度へ及ぼす影響

データセット割合	評価指標			
	1	2	3	4
1.0	0.90	0.53	0.92	2.48
0.8	0.88	0.59	0.89	2.76
0.6	0.87	0.62	0.88	2.93
0.4	0.83	0.68	0.88	4.04
0.2	0.73	0.89	0.80	6.54

(ii) 学習データを一部空調機に限定した場合における精度へ及ぼす影響

サーバールームには複数の空調機が設置されている場合が多い。空調機毎の学習サンプルを収集する必要性により、用意すべきデータセット数は大きく変化する。本内容の検討を目的に、学習データセットから各空調機のデータを除外した際の精度評価を行い、各空調機の学習データがどの程度精度へ影響を及ぼすかを考察する。

表 3-17 に空調機 1 のデータセットを学習データより除外した際の精度評価値を示す。この表より、除外しない場合に比べて、学習データを除外した場合の方が精度評価値は小さくなっているが大きな変化はない。また、各空調機の精度評価値を比較すると大きな差がないことがわかる。

次に、表 3-18 に空調機 2 のデータセットを学習データより除外した際の精度評価値を示す。この表より、除外しない場合の結果に比べて、精度評価値は悪化していることがわかる。また、各空調機の精度評価値を比較すると大きな差がないことがわかる。これは若干であるが、空調機 2 のサンプル数が多い(5 回実験回数が多いことを起因とする)ことが原因と考える。そのため、本検証ルームにおいては空調機 2 を停止させた学習データのみを使用した場合においても、空調機 1、空調機 2 の停止時の予測が同程度の精度であったことから、学習データを減少させることができる可能性があると考えられる。ただし、大規模なサーバールームにおいて、大量の空調機がある場合には本検証ルームと条件が大きく異なるため、同様の事象が適用できるかは再検討が必要である。

表 3-17 空調機 1 のデータセットを学習データから除外した場合の精度評価

停止した空調機	評価指標			
	1	2	3	4
空調機 1(除外あり)	0.85	0.61	0.78	2.41
空調機 1(除外しない場合)	0.89	0.55	0.92	2.46
空調機 2(除外あり)	0.90	0.55	0.92	2.56
空調機 2 (除外しない場合)	0.91	0.52	0.91	2.06

表 3-18 空調機 2 のデータセットを学習データから除外した場合の精度評価

停止した空調機	評価指標			
	1	2	3	4
空調機 1(除外あり)	0.74	0.78	0.85	5.25
空調機 1(除外しない場合)	0.89	0.92	0.55	2.46
空調機 2(除外あり)	0.75	0.80	0.55	4.75
除外しない場合(除外しない場合)	0.91	0.91	0.52	2.06

(iii) 学習データにおける空調停止時間が精度へ及ぼす影響

サービス提供をしているサーバールームにおいて、空調機の停止に関する学習データを収集することは非常に難しい。また、空調機を停止させる時間が長ければ長いほど、温度が上昇していくため学習データに必要な空調機停止時間を把握することは非常に重要である。そこで、学習データセットにおける停止時間の長いデータセットを除いた場合に精度評価値がどのように変化するかを検証した(表 3-19)。空調機停止時間が短いデータセットを使用するほど、評価値は低下することがわかる。10分未満のデータセットのみを用いた場合、決定係数が0.8を下回り、正しい予測ができていないと考える。この原因として考えられるのは、大きく二つある。一つは、学習に使用したサンプル数のサイズが及ぼしたことが推測される。空調機停止時間が短いサンプルの場合、1ケースで取得できるサンプル数が少ない。そのため、本検証において使用可能なデータセット数は、停止時間が短くなるほど、急激に減っていく。二つ目は、外挿への対応が難しく、精度評価値が低下したことが考えられる。これらの結果より、学習データに含まれない事象(短い停止時間の学習で長い停止時間)を予測することは困難と推察する。

表 3-19 停止時間が精度へ及ぼす影響

学習サンプル	評価指標			
	1	2	3	4
除外なし	0.90	0.53	0.92	2.48
10 以下のデータ	0.88	0.58	0.91	3.92
5 分以下のデータ	0.75	0.83	0.81	5.49
2 分以下のデータ	0.46	1.24	0.66	6.63

(iv) 学習データにおける空調機停止前のデータ取得時間が精度へ及ぼす影響

空調機を停止させた後のラック吸気温度を予測する際に本モデルでは空調機停止前の状態を説明変数として用いる。どの程度前の情報を用いる必要があるかという条件は、データ収集システムへの要求仕様・本予測プログラムの実装方法・本予測の使用方法に大きく影響を及ぼすと考えられる。そこで、学習データとして使用可能な停止前の時間を変化させ、精度へ及ぼす影響に関する考察を行う。表 3-20 に学習データとして使用可能な停止前の時間を変化させた際の精度評価値を示す。1 分前のデータを使用できる場合、いずれの評価値も最も良い値を示す。また、1 時間前よりも過去のデータのみ学習データとして使用する場合、1 分前や 30 分前のデータと比較すると値は低下している。また、1 時間前よりも過去のデータを利用した際には決定係数は大きな差が見られないこともわかる。これらの結果より、高い精度での予測を実現するためには、直前のデータを用いることが必要と考える。

表 3-20 停止時間が精度へ及ぼす影響

使用可能な直前のデータ	評価指標			
	1	2	3	4
1 分前	0.90	0.53	0.92	2.48
30 分前	0.87	0.61	0.89	3.84
60 分前	0.82	0.72	0.87	3.72
6 時間前	0.84	0.66	0.89	3.88
1 日前	0.84	0.66	0.88	3.05
3 日前	0.80	0.75	0.84	4.76
7 日前	0.80	0.73	0.86	4.48

3.5 本章のまとめ

本研究では、検証対象のサーバールームにおいて空調機停止後におけるラック吸気温度の時系列変化を高精度に予測するモデルについて、GBDT を用いた予測モデルを構築し、検証を行い、以下結果を得た。

- ・ 予測モデルは、停止後の台数毎にモデルをわけることで、頑健なモデルを構築できることがわかった。
- ・ 各説明変数が精度へ及ぼす影響を明らかにした。
- ・ 本予測モデルの構築するためには、評価用データセット数と同等の学習データセット数を用意することが必要なことがわかった。
- ・ 学習データセットにおいて、停止する空調機が精度への及ぼす影響は小さかった。
- ・ 本予測モデルを使用する場合、直前のデータを使用することが精度向上において重要ということがわかった。

また、本研究は、一つのサーバールームを対象とした事例研究であり、汎用性の評価に関する今後の課題を以下に示す。

- 本研究で対象とした検証対象ルームと異なる条件下におけるルームへの適応性について検討が必要と考える。
 - 本検証ルームと比較して大規模なルームへの適応性
 - アイルキャッピングが設置されているルームにおける適応性
 - 本検証ルームに設置される空調機は空冷式パッケージ型エアコンであるため、その他空冷方式への適応性
- 本研究では、各種学習データが及ぼす影響を明らかにした。汎用的に本シミュレーションモデルを展開した場合に、計算コストが大きくなることが予測されるため、学習期間や学習頻度の最適化(どの程度まで短くできるのか、短くした場合の精度への影響)に関する検討が必要と考える。また、空調機停止に関する学習データの取得は運用上難しいと考える。そこで、擬似データの作成により学習データへ利用した場合の適応性について今後検証したいと考える。
- 本技術の対象であるサーバールームにおける温度逸脱の発生有無に関する確認について、今後設置が予測されている高発熱密度サーバ(10kW/Rack や 20kW/Rack) への対応について、検討することが重要と考える。

本章における参考文献

- [1] ASHRAE Thermal Guidelines: Energy Technologies Area, Berkeley Lab Home Page. Available online:https://datacenters.lbl.gov/sites/all/files/ASHRAE%20Thermal%20Guidelines_%20SVLG%202015.pdf (accessed on 29th June 2020)
- [2] 羽山広文, 木下学, 倉渕隆, 絵内正道: 空調機停止後の発熱分布を考慮した室温上昇に関する研究, 日本建築学会計画系論文集, 66 巻, 543 号, p.41-47, 2001 年 5 月

第4章 省エネ改善実行時におけるエネルギー基準算出手法の研究

4.1 本章の背景と目的

現在のDCで消費される電力は非常に大きい。近年IoTや機械学習に関する技術の利用促進に伴い、DCにおける消費電力も増加することが予測されている。これら背景からわかるように、DCにおける省エネルギー化は喫緊の課題である。特に、DCにおける消費電力の約4割を占める冷却に関する省エネルギーに注目が集まっており、様々な省エネ技術に関する取り組み事例が報告されている。このような省エネ技術や施策をサーバールームへ適用及び推進する際には、①省エネルギー施策の策定、②実施前の温度リスク評価、③省エネルギー施策の実施、④実施した省エネルギー施策の評価の四つのステップを適切に実施することが重要と考える(図4-1)。特に、④の省エネルギー施策の評価において、正確に効果が把握できない場合、DCの運用者や管理者の省エネルギー化に対するモチベーションが低下し、省エネルギー施策を継続することが非常に難しくなることが予想される。そのため、省エネルギー施策の推進や継続的な実施には、効果を正確に把握する手法の確立が必要不可欠と考える。

エネルギー施策による効果は、省エネ技術を導入していない場合のエネルギー消費(ベースライン)との比較が一般的である。このベースラインを作成する方法として、ISO50001では、①過去n年のデータを用いた統計値(平均値や最小値)を使用する方法、②消費電力を推定するモデルを構築する方法等が提唱されている[1]。①のアプローチは、過去データが存在すれば比較が簡易であるが、サーバールームの内部負荷は時間的な変化が大きく、過去データの統計値(平均値や最小値)を利用したベースラインでは、正確な効果を把握することが難しいと考えられる。②のアプローチとして、熱流体シミュレーションを利用し、サーバールームにおける空調機に関する消費電力の推定が可能であるが、本アプローチは、第2章、3章の温度予測技術に関する研究においても記載した通り、ルーム、空調機、及びラック等に関する境界条件の入力・モデリング・計算にかかる時間が膨大になるため、汎用的な展開が難しいという課題が存在する。さらに、部屋の実態等の影響により、シミュレーション結果と実測が乖離することがしばしば見受けられ、モデル単位にチューニングが必要になる場合が多いといった問題も存在する。

そこで、本章では自己学習を特長とする機械学習を用いることで、ある設定温度で運転する空調機の消費電力に関し高精度かつ各ルームに適応可能なベースラインモデルを作成する手法、及び省エネルギー施策を推進するためのプロセスを提案する。また、機械学習手法の選定、及びベースラインモデルの構築・精度検証、異なるサーバールームの計測データにより再学習したベースラインモデルを用い、異なるサーバールームにおける精度検証を行い汎用性を評価した結果を報告す

る。また、省エネ施策を模擬した実験を行い、本章で提案する省エネルギー施策のプロセスに基づき、第 2 章で報告したラック吸気温度を予測する技術と本ベースラインモデルを組み合わせ検証を行った結果及び考察を報告する。




図 4-1 本章で提案する省エネルギー施策のプロセス

4.2 検証対象及び検証データ

4.2.1 検証対象のルーム，設備情報，システム構成

本章における検証対象のルームは，第2章と同様にサーバルームA，サーバルームBとした(図2-1)。そのため，前章と同様の設備，システム構成を検証に用いた。

4.2.2 検証データ

データ取得システムが取得した情報のうち，ICT 装置の消費電力，空調機の消費電力・冷房能力，外気温度の四つを検証用データとして用いた。それぞれ1分間隔，及び5分間隔で収集・蓄積されている各データを，30分間の平均値に加工したものをモデル構築，及び検証に用いた。

また，本章では表4-1に示す期間のデータを用いて評価を行った。No1,2期間における空調機の設定温度は，同じである。No3 期間は，設定温度を変更した際の効果を把握するために設定温度の変更を行っている。なお，No2 期間における2018年6月23日～2018年7月2日の間は全てのデータが欠損していたため，欠損期間として扱い，学習及び評価には使用していない。

表 4-1 データを使用した各期間

期間 No	ルーム	期間
1	A	2017年5月1日～2017年12月31日
2	B	2018年3月1日～2018年8月15日
3	A	2019年10月21日～2019年12月23日

4.3 エネルギー基準算出モデルの構築及び評価指標

(1) モデルの構築

近年、機械学習において予測結果やプロセスについて、人間によって説明可能である Explainable AI(XAI)に注目が集まっている[2][3]。本研究の対象である空調機の消費電力に関する省エネ技術の効果を把握する場合、予測結果の説明力が高いモデルの方がベースラインモデルとして好ましいと考える。そこで本章では、説明力が高いと考える(a)線形回帰 (python の scikit-learn に実装されているライブラリ Linear Regression を使用), (b)決定木 (python の scikit-learn に実装されているライブラリ Decision tree Regression を使用), の二つの手法に加え決定木モデルの応用である(c)Gradient boosting decision tree (python の scikit-learn に実装されているライブラリ xgboost を使用)の三つの手法を選定した。(c)の GBDT に関して、第二章と同様にハイパーパラメータは、「葉の枚数」・「L2 正則化の重み」・「木の本数」についてグリッドサーチ法にて最適化する設定を用い、上記以外のパラメータはデフォルト値を用いた。各手法の選定について、No1 期間において、ベースラインモデルの精度を検証し、詳細な評価を加え、サーバールームにおける空調機に関する消費電力を推定するベースラインモデルの手法選定する。

本研究の目的である各サーバールームの空調機に関する消費電力を目的変数に設定した。なお、サーバールーム A の空調機 2 は停止状態のため目的変数から除外した。説明変数は、効果検証時に利用可能な説明変数として、空調機の冷房能力、外気温度、ICT 装置の消費電力の三つを選定した。検証期間の n 日前までのデータを学習期間としたベースラインモデルを構築した。なお、手法の汎用性について、異なるサーバールームにおける空調機にベースラインモデルを適応した際の検証を行い、汎用性を評価する。また、No3 期間において、ベースラインモデルを用いた省エネ施策の効果検証を行う。

(2) モデルの評価

空調機の消費電力に関する実測値(以下, 実測値)とベースラインモデルより推定した予測値(以下, 予測値)を用いて精度を評価する. 本章で提案するベースラインモデルは 3 つの指標で精度を評価した. なお, また, 第二章, 第三章で用いた正解率は, サーバルームのラック吸気温度の推奨領域が提唱されているため有用と考え設定した[2]. しかし, 本章の目的変数である空調機の消費電力について, 機器仕様毎に異なる数値のため $n\%$ 以内に収まるという評価指標では, モデルの汎用性を評価することが難しいと考え除外した.

(1)相関係数

実測値と予測値の相関係数を算出し, 精度を評価する

(2)Root Mean Square Error (RMSE)

予測等評価の指標として一般的に用いられる RMSE により精度を評価する

(3)ピーク誤差

評価期間において, 予測値が実測値を最も上回った値を本章におけるピーク誤差と定義し, 評価する. これは, 省エネ施策を実施していない場合の基準として使用するため, 予測値が実測値と比較し大きくなる事象は省エネ効果を過大に評価してしまう可能性があるため, 本評価指標を設定した.

4.4 エネルギー基準算出モデルの精度評価

4.4.1 エネルギー基準算出モデルの精度評価及び手法の選定

(1) No1 期間における各手法に関する精度比較

No1 期間において、学習期間、及び検証期間をそれぞれ 1 カ月間と設定し、各手法を用いた予測モデルの構築、及び精度評価を行った(表 4-2,表 4-3)。これらの値は、評価指標(1)~(2)は各月における評価値の平均、評価指標(3)は各月の最大値を使用した。この結果より、全ての評価値において手法(c)が最も良い値を示し、手法(a)は最も悪い結果を示した。また、(b)の手法用いた予測モデルの評価値は、(c)の手法を用いた評価値と比べ悪い結果であった。これは、(c)の手法が(b)の手法に対して重み付けを行うブースティングを加えた手法であることから、ブースティングの有無が精度に影響を及ぼしたと考えられる。

表 4-2 学習・評価期間の関係(No1 期間)

2017 年							
5 月	6 月	7 月	8 月	9 月	10 月	11 月	12 月
学習	評価						
	学習	評価					
		学習	評価				
			学習	評価			
				学習	評価		
					学習	評価	
						学習	評価

表 4-3 No1 期間における各手法の各評価指標値

手法	評価指標		
	(1)	(2)	(3)
(a)線形回帰	0.82	1.00	4.75
(b)決定木	0.85	0.61	3.11
(c)GBDT	0.88	0.56	2.56

(2) No1 期間における各月単位の各手法に関する精度比較

次に、各月ごとの評価値を表 4-4、図 4-2、表 4-5、図 4-3、表 4-6、図 4-4 に示す。

表 4-4、図 4-2 に示す相関係数について、いずれの手法も高い相関がある数値を示しており、高い精度での予測ができていると考えることができる。ただし、手法(a)と手法(b)は他の 2 つの手法の何れと比較しても悪い値を示す月が存在する((a):6 月, 12 月／(b):7 月, 8 月, 9 月)。一方で、手法(c)は、3 つの手法のなかで最も悪い値を示す月はなく、かつ最も良い値を示す月が多い結果が得られた。

表 4-5、図 4-3 に示す RMSE について、手法(a)は 3 つの手法の比較において最も良い値を示す月はなく、月による変動も他の手法と比較して大きい。また、手法(b)と手法(c)の RMSE は近い値を示した。相関係数と同様にわずかな差ではあるが手法(c)の方が良い値を示す月が多い結果が得られた。

表 4-6、図 4-4 に示すピーク誤差について、手法(a)は他の 2 つの手法と比較して良い値を示す月が複数存在(7 月, 10 月, 12 月)するが、月による変動が他の手法と比較して大きい(最小: 0.48kW(7 月), 最大: 4.75kW(9 月))。また、手法(b)と手法(c)のピーク誤差は近い値を示すが、手法(c)の方が良い値を示す月が多い結果が得られた。

これらの結果より、手法(a)は月によって予測精度に係る評価指標が変動したのでベースラインのモデルとしては不適と考える。また、手法(b)と手法(c)について、いずれも高い相関係数を示し、高い精度で予測が可能と考える。ただし、手法(b)と比較して総じて良い値を示した手法(c)がベースラインモデルとして頑健性が高く、適していると考え、以後手法(c) を使って評価を行うこととする。

表 4-4 各月における各手法の相関係数

手法	2017 年度の月別相関係数						
	6 月	7 月	8 月	9 月	10 月	11 月	12 月
(a)線形回帰	0.77	<u>0.90</u>	0.87	0.87	0.94	0.67	0.67
(b)決定木	0.84	0.85	0.84	0.84	0.94	<u>0.75</u>	0.91
(c)GBDT	<u>0.90</u>	0.89	<u>0.89</u>	<u>0.88</u>	<u>0.95</u>	0.70	<u>0.94</u>




図 4-2 各月における各手法の相関係数

表 4-5 各月における各手法の RMSE

手法	2017 年度の月別 RMSE						
	6 月	7 月	8 月	9 月	10 月	11 月	12 月
(a)線形回帰	2.35	0.61	0.67	0.68	0.56	0.84	1.28
(b)決定木	0.83	0.69	0.64	0.64	<u>0.44</u>	<u>0.37</u>	0.69
(c)GBDT	<u>0.66</u>	<u>0.62</u>	<u>0.56</u>	<u>0.57</u>	0.54	0.41	<u>0.61</u>




図 4-3 各月における各手法の RMSE

表 4-6 各月における各手法のピーク誤差

手法	2017 年度の月別ピーク誤差						
	6 月	7 月	8 月	9 月	10 月	11 月	12 月
(a)線形回帰	3.85	0.48	4.71	4.75	0.68	0.51	0.40
(b)決定木	2.20	1.10	<u>2.20</u>	2.37	2.78	<u>2.35</u>	3.11
(c)GBDT	<u>1.64</u>	<u>0.75</u>	2.22	<u>2.20</u>	<u>1.14</u>	2.56	<u>2.16</u>




図 4-4 各月における各手法のピーク誤差

4.4.2 説明変数及び学習データが精度へ及ぼす影響

(1) 説明変数が精度へ及ぼす影響

予測モデルを構築する際に、説明変数の選定は非常に重要である。学習期間が精度に対し影響を与えるだけでなく、モデル構築に要する時間が大きく変化するためである。さらに、ベースラインモデルを用いて省エネ効果の検証する場合、省エネ効果を実施していない推定値がユーザに理解が可能、もしくは説明が可能なことが重要であると考えられる。そこで本項では、ベースラインモデルにおける各説明変数が精度に及ぼす影響を調査するために、説明変数の重要度を算出した。この重要度は、各説明変数が精度向上にどの程度寄与したかを意味する。11 月を学習期間・12 月を評価期間とした際のモデルについて、python の既存ライブラリを使用し算出((xgb.plot_importance(x)), デフォルトの gain 使用)した結果を図 4-5 に示す。この結果より、最も精度に影響するのは冷房能力であることがわかる。また、その他の説明変数についても、値は半分以下となるが、無視できない程度の値を示しており重要な説明変数として考えられる。手法(a)や手法(b)と比較して、複雑な手法であるが、図に示すような目的変数に対する説明変数の重要度を示すことで、ロジックを一部理解することが可能である。




図 4-5 ベースラインモデル構築における説明変数の重要度

(2) 学習期間が精度へ及ぼす影響

学習期間の長さが及ぼす精度への影響を考察するため、評価期間を1か月間(11月, 12月)と固定し、学習期間を直前1週間から直前6ヶ月と変化させる(表4-7)。学習期間を変化させた際の評価期間1か月(11月, 12月)の精度に関する評価指標値を表4-8, 表4-9に示す。これらの表より、直前3週間以上の学習期間の場合、学習期間と評価値の関係は小さいと考えることができる。一方で、1週間などの評価期間に対して非常に短い期間の場合、精度値は低下するという結果が得られた。

表4-7 学習・評価期間の関係

学習期間 No	学習期間	評価期間
1	直前1週間	1か月間(11月, 12月)
2	直前2週間	
3	直前3週間	
4	直前1か月間	
5	直前2か月間	
6	直前3か月間	
7	直前4か月間	
8	直前5か月間	
9	直前6か月間	

表4-8 学習期間を変化させた際の評価指標(評価月11月)

評価指標	学習期間 No								
	9	8	7	6	5	4	3	2	1
(1)	0.67	0.53	0.60	0.59	0.52	0.70	0.74	0.52	0.51
(2)	0.56	0.78	0.61	0.70	0.76	0.41	0.39	0.48	0.46
(3)	2.17	3.11	2.51	2.54	2.81	2.56	2.38	2.36	2.39

表4-9 学習期間を変化させた際の評価指標(評価月12月)

評価指標	学習期間 No								
	9	8	7	6	5	4	3	2	1
(1)	0.94	0.94	0.95	0.95	0.94	0.94	0.94	0.94	0.88
(2)	0.59	0.62	0.60	0.58	0.62	0.62	0.60	0.63	0.99
(3)	1.36	1.31	1.61	1.64	1.96	2.16	2.11	1.90	1.64

4.4.3 異なるルームにおける本手法の適用性に関する考察

(1) No2 期間全体における精度評価

サーバルーム B において、学習期間、及び検証期間をそれぞれ 1 カ月間と設定し、モデルの構築、及び精度評価を行う。(表 4-10). 評価指標は、サーバルーム A と同様の方法を使用した。また、サーバルーム B では全期間において空調機 3,4 のどちらも運転されている。そのため、空調機単位にベースラインモデルを構築し、精度評価を実施した(表 4-11)。この結果より、前節で検証したベースラインモデルを適用した場合においても、いずれの空調機も高い相関係数を示しており、高い精度のベースライン推定が可能と考えられる。なお、各空調機 4 に比べて空調機 3 の方が高い指標値を示したため、次項で各月単位における詳細な精度評価を行い、考察を加える。

表 4-10 学習・評価期間の関係(No2 期間)

2018 年					
3 月	4 月	5 月	6 月	7 月	8 月
学習	評価				
	学習	評価			
		学習	評価		
			学習	評価	
				学習	評価

表 4-11 No2 期間における各空調機の各評価指標値

空調機 No	評価指標		
	(1)	(2)	(3)
空調機 3	<u>0.95</u>	<u>0.26</u>	<u>0.94</u>
空調機 4	0.76	0.64	1.34

(2) No2 期間における各月単位の精度比較

次に、各空調機における各月ごとの評価値を表 4-12、表 4-13 に示す。表 4-12 に示す空調機 3 の結果より、各月も同様に高い精度でベースラインを推定したことがわかる。ただし、空調機 3 は空調機 4 に比べて、圧縮機の運転時間が非常に低い。これは対象のサーバルームにおける内部負荷に対し、2 台の空調機に関する冷房能力が大きく、空調機 3 は送風運転の状態が多いためである。そのため、送風運転の期間は消費電力の値及び変化も非常に小さく、推定が容易だったことが空調機 4 と比較して精度が高かった要因の一つであると考ええる。一方で、表 4-13 に示す空調機 4 の結果では、7 月の評価値が他の月に比べて悪いことがわかる。この要因について、2018 年 6 月 23 日~2018 年 7 月 2 日の間のデータが欠損しているおり、2018 年 7 月の評価期間(7 月 3 日~7 月 31 日)において、直前データが欠損していることから精度が低下していると仮説を立てた。仮説検証のために、2018 年 7 月の評価期間を 7 月 4 日~7 月 31 日、学習期間は、6 月 1 日~6 月 22 日と直前のデータとして 7 月 3 日を組み合わせさせたデータで、精度検証を行った(表 4-14)。直前のデータを加えることで、精度評価値が他の月と同様に高くなり、高い精度でのベースライン推定が可能になったと考えられる。この結果より、ベースラインモデルを構築する際には推定月の直前にデータ欠損した場合、精度が低下すると考えられ、省エネ施策の効果を検証するには注意する必要がある。

表 4-13 2018 年 4 月~8 月における空調機 3 に関する評価値

評価指標	2018 年の空調機 3 における各評価値				
	4 月	5 月	6 月	7 月	8 月
(1)	0.87	0.95	0.95	0.99	0.99
(2)	0.28	0.30	0.33	0.20	0.19
(3)	0.60	0.84	0.94	0.49	0.49

表 4-13 2018 年 4 月~8 月における空調機 4 に関する評価値

評価指標	2018 年の空調機 4 における各評価値				
	4 月	5 月	6 月	7 月	8 月
(1)	0.90	0.86	0.83	<u>0.36</u>	0.85
(2)	0.46	0.41	0.34	<u>1.96</u>	0.34
(3)	1.20	2.03	1.50	<u>1.55</u>	0.66

表 4-14 7 月の学習期間を変更した際の空調機 4 に関する評価値

評価指標	2018 年の空調機 4 における各評価値				
	4 月	5 月	6 月	7 月	8 月
(1)	0.90	0.86	0.83	<u>0.90</u>	0.85
(2)	0.46	0.41	0.34	<u>0.49</u>	0.34
(3)	1.20	2.03	1.34	<u>1.34</u>	0.66

(★7月以外は表 15、表 16 は同じ)

(3) サーバルーム B における空調機に関する説明変数が精度に及ぼす影響

サーバルーム B における各空調機に関して、説明変数がベースラインモデルに及ぼす影響を前項と同様の方法で評価した。各空調機における各説明変数の重要度を図 4-6 に示す。図 4-6 に示すようにサーバルーム A と同様に最も重要度が高かった説明変数は対象の空調機に関する冷房能力であった。本提案するベースラインモデルは、異なるサーバルーム・異なる空調機においても、説明変数が精度へ及ぼす影響が類することがわかった。




図 4-6 空調機 3,4 に関する各説明変数の重要度

4.5 省エネルギー施策実施時における効果検証

4.5.1 効果検証の概要

本項では、本節において実施する省エネルギー施策を模擬した実験及び効果検証の概要を記載する。本節では、空調機の戻り温度に関する設定を変化させた実験を行い、第二章で議論したラック吸気温度を予測する技術と本章で議論したベースライン技術を用い、省エネルギー施策実施に関するプロセスの提案及び有効性を議論する。

本節における検証は、サーバールーム A を対象とし、表 4-1 に示す期間 No3 において、ラック吸気温度及びベースラインモデルを構築し、空調機の戻り温度に関する設定温度を上げた際(区間 No2)の事前リスク評価及び省エネ施策の効果把握を行う。また、空調機の戻り温度に関する設定温度を下げた際の実験(区間 No4~区間 No7)を行い、ベースライン技術の効果把握に関する追加検証を行った。表 4-15 に、No3 期間における学習期間と検証期間と併せて空調機の戻り温度に関する設定温度、各期間の検証に使用したデータ数を点数として示す。期間 No1 と同様に期間 No3 においても戻り温度は 28℃を通常の状態とする。

表 4-15 期間 No3 における学習期間と検証期間及び空調機に関する戻り温度の設定温度

区間 No	開始日時	終了日時	点数	設定温度	備考
1	2019/10/21 0:00	2019/11/20 23:30	1489	28℃	学習期間
2	2019/11/21 15:00	2019/12/6 13:00	706	30℃	評価期間
3	2019/12/6 13:30	2019/12/10 13:00	192	28℃	
4	2019/12/10 13:30	2019/12/12 13:30	97	26℃	
5	2019/12/12 14:00	2019/12/16 14:00	193	24℃	
6	2019/12/16 14:30	2019/12/18 14:30	97	22℃	
7	2019/12/18 15:00	2019/12/20 13:00	92	20℃	

4.5.2 ラック吸気温度予測モデル及びベースラインモデルの構築

(1) ラック吸気温度予測モデルの構築

期間 No3 における区間 No1 のデータについて、2019 年 10 月 21 日～2019 年 11 月 7 日を学習期間、2019 年 11 月 8 日～2019 年 11 月 20 日を検証期間と二分割し、第 2 章で議論した状態空間モデルを用いてモデルを構築・検証した。ただし、この際に、説明変数を空調機の戻り温度、ラック消費電力、1 時点前のラック吸気温度の三つを以下理由より選定した。

空調機の戻り温度は、第 2 章で議論した通りラック吸気温度の予測において重要な変数である。更に、空調機の戻り温度に関する設定を変化させた実験を行うため、事前リスク評価を行う際に必要不可欠な変数のため選定した。ラック消費電力は、サーバールームにおける内部負荷を示しており、重要と考え選定した。1 時点前のラック吸気温度は、状態空間モデルを用いる際には必要な変数のため、説明変数として用いた。

精度検証の結果を表 4-16 に示す。この結果は第 2 章で議論した精度と同等の評価指標値を示しており、高い精度でのモデルを構築できたと考える。

表 4-16 区間 No1 期間のデータにおけるラック吸気温度予測モデルの精度評価値
(検証期間 2019 年 11 月 8 日～2019 年 11 月 20 日)

モデル名	評価指標			
	相関係数	RMSE	正解率	ピーク誤差
状態空間モデル	0.99	0.14	0.98	2.37

(2) ベースラインモデルの構築

次に、空調機に関する戻り温度 28℃で運転された区間 No1 及び No3 のデータセットを用いて、ベースラインモデルの精度評価を行う。学習期間を区間 No1 (2019 年 10 月 21 日～2019 年 11 月 20 日) の 1 か月と設定し、ベースラインモデルを構築した。評価期間として設定した区間 No3 (2019 年 11 月 21 日～2019 年 12 月 23 日) において、構築したベースラインモデルを用いて算出した値と実測値を比較し精度検証を行った(表 4-17)。この結果より、本章で議論した内容と同程度の評価値を示したことから、高い精度での予測が可能なベースラインモデルと考えることができる。そのため、次項以降において、本モデルを用いて省エネルギー施策の効果を検証する。

表 4-17 区間 No3 におけるベースラインモデル各評価指標値

モデル名	評価指標		
	決定係数	RMSE	ピーク誤差
GBDT	0.91	0.26	0.49

4.5.3 本研究で提案する省エネルギー実施に関するプロセスの検証

(1) 空調機の戻り温度に関する設定変更(30℃へ変更)

本章で提案するエネルギー施策を実施・推進するプロセスは、①省エネルギー施策の策定、②実施前の温度リスク評価、③省エネルギー施策の実施、④実施した省エネルギー施策の評価の四つのステップです。

①省エネルギー施策の策定では、空調機の戻り温度に関する設定温度を 30℃に上昇させる実験と設定した。

①省エネルギー施策の策定後、設定温度を 30℃に上昇させた際にラック吸気温度が上昇しないかを②実施前に温度リスクを事前評価する。ラック吸気温度予測モデルを用い、説明変数にはそれぞれ次の入力値を設定する。まず、空調機の戻り温度には設定温度 30℃を入力する。また、1 時点前のラック吸気温度は省エネルギー施策の実施 1 時点前の値を入力値とした。ラック消費電力について、DC における各ラック消費電力を予測することは非常に難しいため、温度環境に対する条件が厳しくなる過去 1 か月間における最大値を入力値として設定した。これらの入力値は、過去 1 か月における最大の内部負荷に対して、設定温度を変更した場合のラック吸気温度を予測することを意味しており、この予測値より省エネルギー施策の温度リスクの有無を判断する。表 4-18 に、これら入力値とラック吸気温度予測モデルから出力された予測値と評価期間における実測値の最大値・平均値を比較した。この表から、予測結果は実測値の平均値と非常に近い値を示していることがわかります。また、全ラックにおける予測結果と実測値の最大値の誤差は 2.33℃であり、前項において示したピーク誤差である 2.37℃(表 4-16)の範囲内であることがわかる。この結果より、モデル構築時において評価したピーク誤差値は、モデルの保持する最大誤差と見なすことが可能であり、評価期間中に発生する可能性のある誤差と捉えることができると考える。図 4-7 に評価期間における実測値の最大値と、(予測値+ピーク誤差 2.37℃)を比較した図を示す。(予測値+ピーク誤差 2.37℃)を事前評価で用いる場合、評価期間中のいずれの最大値よりも高いため、フェールセーフな考え方となる。また、表 4-18, 図 4-7 から、どのラックが高温になるかの予測ができているため、省エネ対策を実施する際に留意する点を事前に把握も可能である。これらの結果より、本ラック吸気温度を予測するモデルを事前のリスク評価に利用することは有効であると考ええる。

②実施前の温度リスク評価の実施後に、区間 No2 における期間で③省エネルギー施策を実施した。次に、本章で提案したベースラインモデルを用いた④実施した省エネルギー施策の評価を行った。空調機に関する戻り温度を 30℃に設定変更した際の実測の消費電力とベースラインモデルによる予測値との差分から算出した省エネ効果を表 4-19, 時系列変化を図 4-8 に示す。約 14 日間設定温度を 2 度緩和することにより、消費電力が約 50kW の削減効果があったと捉えることができる。

また、図 4-8 からは同様の傾向で時系列変化することに加え、ベースラインの方がわずかではあるが高い値を示す割合が高いことがわかる。これらの結果より、本ベースラインモデルを活用することで省エネルギー施策の効果を定量的に把握することが可能なことを確認した。

表 4-18 評価期間におけるラック吸気温度の予測値、及び実測値における最大値・平均値との

関係

ラック名	予測値	実測値の最大値	(実測値の最大値-予測値)	実測値の平均値	(実測値の最大値-予測値)
A1	30.36	32.62	2.26	30.77	0.41
A2	29.52	31.45	1.93	29.52	-0.01
A3	30.63	32.61	1.98	31.09	0.46
A4	29.56	31.57	2.01	29.16	-0.40
A5	33.46	35.00	1.54	32.82	-0.64
A6	29.99	32.11	2.12	29.54	-0.45
A7	31.15	33.35	2.19	31.21	0.05
B1	30.86	32.89	2.03	31.09	0.23
B2	29.31	31.09	1.78	29.04	-0.28
B3	29.48	31.45	1.97	29.11	-0.37
B4	31.48	33.58	2.10	31.43	-0.04
B5	29.38	31.34	1.96	29.47	0.09
B6	31.76	34.06	2.30	31.61	-0.15
B7	29.13	31.46	2.33	29.03	-0.10
C1	30.38	32.67	2.29	30.86	0.47
C2	30.20	32.3	2.10	30.71	0.51
C3	32.85	34.92	2.08	33.15	0.31
C4	29.66	31.44	1.78	29.72	0.06
C5	29.05	30.76	1.71	29.14	0.09
C6	29.87	31.82	1.95	30.01	0.15
C7	28.80	30.53	1.73	28.87	0.07
D1	30.25	32.00	1.745	30.45	0.20
D2	29.99	31.77	1.78	30.20	0.21
D3	30.83	33.09	2.26	31.11	0.28
D4	30.01	31.49	1.48	29.84	-0.17
D5	29.53	31.14	1.61	29.34	-0.18
D6	28.88	30.73	1.85	29.03	0.15
D7	28.62	30.50	1.88	28.83	0.20

表 4-19 設定温度を 30℃に変更した際の省エネ効果

区間 No	点数	設定温度	(実測値—ベースライン) 706 点の総和
2	706	30℃	-49.15kW




図 4-7 各ラックにおける実測値の最大値と、(予測値+ピーク誤差 2.37°C)の比較




図 4-8 空調機の戻り温度に関する設定温度を 30°Cに変更した際の実測の消費電力とベースラインの時系列変化の比較(区間 No2)

(2) 空調機の戻り温度に関する設定変更 (20~26℃へ変更)

ベースラインモデルの確からしさを確認するために、空調機の戻り温度に関する設定温度を下げた追加検証を行った。なお、設定温度を下げるため本追加検証では、温度リスクの事前評価は除外した。空調機に関する戻り温度を 20℃~26℃に設定変更した際の実測の消費電力とベースラインモデルによる予測値との差分から算出した効果を表 4-20、各値の時系列変化を図 4-9 に示す。設定温度を下げることで消費電力が増加する効果があったと捉えることができる。また、図 4-9からはベースラインの方が低い値を示していることがわかる。この結果より、ベースラインモデルによる予測値を用いることで、設定温度を下げた場合のエネルギー増加を定量的に評価が可能なことを確認した。

表 4-19 設定温度を 20~26℃に変更した際の消費エネルギーへの影響

区間 No	点数	設定温度	(実測値—ベースライン) 各点数の総和
4	97	26℃	33.05
5	193	24℃	37.76
6	97	22℃	13.67
7	92	20℃	126.97




図 4-9 空調機に関する戻り温度を 20℃に設定変更した際の実測の消費電力とベースラインの時系列変化の比較(区間 No7)

4.5.4 過去データを使用した場合のベースラインモデルとの比較

省エネ効果を検証する場合に、過去データを用いる場合がある。機械学習を用いたモデルを利用することの特長を確認するために、2019 年 11 月の消費電力を前年度の消費電力(空調機に関する戻り温度の設定温度は 28°C)を使用した場合の効果検証を行う。各年度の空調機 1 に関する消費電力の実測値、及び 2019 年データを用いたベースラインモデルによる予測値の時系列変化を図 4-10 に示す。この結果からわかるように、空調機の戻り温度(28°C)が同じで、かつ期間(11 月 1 日～20 日)も同じであっても過去の空調機消費電力の実績をベースラインとして扱うのは難しい。これは前述したように、内部負荷の状況が時間的に変化していることから昨年度データを使用することが難しいことが原因と考えることができる。




図 4-10 空調機 1 の消費電力に関する 2019 年度実測消費電力と 2018 年度実測消費電力、及びベースラインの比較

4.6 本章のまとめ

本研究では、サーバルーム A における空調機の消費電力に関するベースラインモデルを構築し、高い精度で空調機消費電力の予測値推定が可能なことを確認した。また、ベースラインモデルの説明変数、学習期間のそれぞれが精度へ及ぼす影響に関する考察した。さらに、同規模の異なるサーバルーム B において、このベースラインモデルを用いた検証を行い、サーバルーム A と同様に高い精度での予測が可能なことを確認し、本ベースラインモデルの汎用性を確認した。一事例ではあるが、ベースラインモデルを用いて省エネ施策の効果を検証する実験を行い、ベースラインモデルの有用性を示した。

また、本章で提案する手法に関する今後の課題を以下に示す。

- 本研究で対象とした検証対象ルームと異なる条件下におけるルームへの適応性について検討が必要と考える。
 - 本検証ルームと比較して大規模なルームへの適応性について検討が必要
 - 本検証ルームに設置される空調機は空冷式パッケージ型エアコンであるため、その他空冷方式への適応について検討が必要
- 本研究では ICT 装置の負荷を予測が困難と考え、過去期間における最大値を使用してリスク評価を行った。そのため、運用者は最大リスクの値として把握する。しかし、ICT 装置の負荷に関するシナリオを作成が可能な場合、各ラック吸気温度について発生する温度の確率（発生頻度）を計算可能にあるため、リスクが起これる可能性として判断することが可能になるため、運用上利便性が高いと考えられる。今後は ICT 装置側の負荷に関するシナリオ作成・シナリオの使用に関する妥当性について検討を加えたい。

本章における参考文献

- [1] 一般社団法人電子情報技術産業協会, 国際標準のエネルギー管理手法~EnPI 導入ガイド~実践編 [ISO 引用版], 2015 年
- [2] Matt, T. Gunning, Explainable artificial intelligence (XAI), Defense Advanced Research Projects Agency (DARPA), June 2018. Available online: <https://www.darpa.mil/program/explainable-artificial-intelligence> (accessed on 31 August 2020)
- [3] Amina, A.; Mohammed, B. Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI). IEEE Access volume 6, IEEE, September 2018.

第5章 結論

5.1 本研究のまとめ

本研究は、DC において統合管理した情報を活用し、運用者や保守者が高品質なデータセンタサービスを提供するためのサーバールームの管理手法及びシミュレーション手法、省エネルギー施策が及ぼす効果の評価手法に関する知見を得た。

第1章「序論」では、以下内容を示した。

DC は、社会生活において非常に重要なインフラの一つになっており今後も重要性が増していくことが予測される。DC における消費電力は、世界の消費電力における約 1%を占め非常に多くの消費電力を消費しているため、省エネルギー化は喫緊の課題であることを示した。また、DC は様々な先端技術の導入に伴い、非常に複雑な環境下のもと、高い信頼性かつ高効率な運用が求められており、特に適正な温度管理が非常に難しく、DC 運用・管理における課題となっていることを示した。このような環境における運用・管理について、従来の個別管理から統合管理の必要性が高まり、統合管理による課題解決が求められているが現状は「見える化」にとどまり、統合管理しているデータの活用ができていないことを述べた。このような背景や課題に対し取り組んだ本研究の目的、及び関連する既往の研究について概説し、本研究の位置付けを示した。

第2章「空調機運転時における室温予測手法の研究」では、ICT 装置及び空調装置から取得可能な情報を説明変数と定義し、各説明変数が変化した場合の温度環境へ及ぼす影響を考慮したサーバールームの運用・管理手法の考察を行った。取得した情報と機械学習を組み合わせ、各説明変数を入力値とし、1 時点先の各ラック吸気温度を出力するシミュレーションモデルを構築した。構築したモデルに関する評価指標を定義し、機械学習の手法を複数比較検討しサーバールームにおける温度環境を管理するモデルとして状態空間モデルを提案した。また、機械学習と熱収支式を組み合わせることによる予測精度へ及ぼす影響について考察した。さらに、シミュレーションモデルの説明変数が予測精度へ及ぼす影響について考察を加え、空調機の戻り温度が予測精度に最も寄与している変数であることを明らかにした。また、本モデルでは直前 1 週間を学習期間に設定することで高い精度で予測が可能であることを確認した。また、本モデルにおける学習頻度が精度へ及ぼす影響について、学習頻度を短くすることで約 10%の精度改善が観察され、運用時における計算コストと精度を検討する際の一考を加えた。

第3章「空調機停止時における室温予測手法の研究」では、サーバールームにおける空調機が停止した場合の温度環境を考慮したデータセンタの運用・管理手法の考察を行った。各種情報からシミュレーションに用いる説明変数及び学習データを定義し、機械学習を用いた空調機停止後に

における各ラック吸気温度の時系列変化を出力するシミュレーションモデルを構築した。複数のシミュレーションモデルを構築・比較検証し、空調機停止台数別に構築したシミュレーションモデルは、検証データに対して頑健なモデルが構築可能なことを明らかにした。また、シミュレーションモデルに関する説明変数の重要度が見える化し、空調機の冷房能力が重要な変数であることを明らかにした。また、停止前の空調機運転台数、及び学習データに関する学習頻度や量が予測精度へ及ぼす影響を検証し、各項目が及ぼす影響に加え、運用時におけるデータ収集システムの仕様やデータ収集方法について考察した。これらの結果、空調機停止後におけるラック吸気温度の時系列変化を事前に高い精度で予測可能なことを確認し、保守者が空調機の点検時や故障時における空調機停止時における温度環境へ及ぼす影響を事前に検討可能なことを示した。

第4章「省エネ改善実行時におけるエネルギー基準算出手法の研究」では、省エネルギー施策を実施する場合に必要な業務工程を定義し、省エネルギー施策を推進するためには施策の効果を定量的かつ正確に評価することが重要、かつ課題であることを考察した。そこでエネルギー管理を実施する運用者や保守者が省エネルギー施策の効果を定量的に把握するための基準値を算出するモデルを構築した。サーバールームの特性を加味して、省エネルギー施策を実施していない場合の消費電力推定値(ベースライン)を算出する機械学習を用いたモデルを提案した。特に、本モデルでは省エネルギー施策の実施者が算出された効果に対して納得感があることが重要と考え、モデルの説明力という観点を加え機械学習の手法を複数選定し、本問題において重要となると考え定義した評価指標により、各手法の比較検討を行った。また、一般的に用いられる過去の統計値を用いた基準値と提案するモデルを用いた基準値を比較し、提案したモデルの方が過去の統計値を利用した場合に比べて高精度にベースラインを算出可能なことを確認した。さらに、省エネルギー施策を模擬した検証を行い、本モデルによる効果の見える化が可能なことを示した。

以上、本研究はDCの運用者及び保守者を対象とし、継続的な運営を支援することを目的とした、高品質なデータセンタサービスの提供を支援する温度環境の運用・管理手法及びシミュレーション手法、省エネルギー施策を継続的に実施するための効果の評価手法及びシミュレーション手法に関する知見を獲得した。本知見を活用することで、継続的なDC運営・データセンタサービスの高品質化に貢献できると考えられる。

5.2 今後の課題と展望

本研究において、検証対象のサーバルームにおける室温予測の手法、及び省エネ改善実行時におけるエネルギー基準算出手法の有効性を示した。その一方で、検証対象と異なる条件下におけるサーバルームへの適応性や、大量のサーバルームを対象とした際の学習データの計算コストを加味した最適化などは今後の課題と考える。

本研究で提案する機械学習を用いたサーバルームにおける施設管理手法及び本研究で得られた知見は、高品質な DC サービスの提供や高効率な DC の運営を目指す DC 運用者や管理者の業務を支援可能だと考える。今後は、本研究で提案する手法の異なる条件下における適応性の検討や計算コストを加味したモデル構築における学習データの最適化等の汎用性に関する検討に取り組むことで、より多くの DC の運営に貢献できることを目指したい。また、DC において統合管理するデータについて、機械学習等を用いた分析を活用することで、DC サービスの高品質化や高効率化に貢献(見える化以上の効果)できる可能性を示した。そのため、DC の運営における課題に対し、データを活用することで改善可能な技術開発にも努めることで、DC の統合管理・高品質なサービス提供・高効率な DC 運営に関する推進に貢献していきたいと考える。

謝辞

本研究の遂行・本論文の完成にあたり、終始懇切なるご指導とご鞭撻を賜りました北海道大学大学院工学院、羽山広文特任教授に深く感謝申し上げます。

北海道大学大学院工学院、長野克則教授、林基哉教授、森太郎准教授には論文審査委員として多くの貴重かつ有益なご指導、ご指摘を頂きました。ここに、御礼申し上げます。

本論文は、NTT ファシリティーズの業務の一環として完成をみたものであり、NTT ファシリティーズ研究開発部をはじめとする諸先輩方のご高配とご支援の賜物と考えております。多忙な業務の中で、本研究への取り組みにおいて、豊田耕造様、泉井太様、山村晃永様、佐々木秀紀様、吉田献一様、小松正佳様、渡邊剛様、篠原廣宣様、青木健様、河野正人様には、研究に関するご指導、さらには研究遂行にあたり業務面で最大限のご配慮を頂きました。ここに、御礼申し上げます。

また、本論文及び本論文を構成する査読論文に関して、度重なるご迷惑・ご心配をおかけした小生ですが、懇切かつ多大なるご指導及びご鞭撻を賜りました小松正佳様のおかげで今回博士論文をまとめあげることができました。重ねて御礼申し上げます。

最後になりますが、論文執筆に理解をし、最大限の配慮と協力をしてくれた妻 直子、学位取得を応援してくれた娘 陽菜乃・心乃美、温かく応援してくれた両親に心より感謝します。

本論文に関連する論文及び講演論文

1. 論文

- (1) 笹倉康佑, 小松正佳, 青木健, 渡邊剛: 機械学習モデルを活用したサーバールームにおける温度環境の管理手法に関する研究 第 1 報 ラック吸気温度の予測モデルに関する提案, 空気調和・衛生工学会論文集, No.278, pp1-8, 2020 年 5 月
- (2) 笹倉康佑, 小松正佳, 青木健, 渡邊剛: 機械学習モデルを活用したサーバールームにおける温度環境の管理手法に関する研究 第2報 パッケージ空調機消費電力推定モデルによる設定温度変更時の評価, 空気調和・衛生工学会論文集, No.282, pp11-18, 2020 年 9 月
- (3) Sasakura K., Aoki T., Komatsu M., Watanabe T.: Rack Temperature Prediction Model Using Machine Learning after Stopping Computer Room Air Conditioner in Server Room, *Energies* 2020, 13(17), 4300; doi: 10.3390/en13174300
- (4) Sasakura K., Aoki T., Komatsu M., Watanabe T.: Temperature-risk and Energy-saving Evaluation Model for Supporting Energy-saving measures for Server Rooms in Data Centers, *Energies* 2020, 13(19), 5222; <https://doi.org/10.3390/en13195222>

2. 講演論文

- (1) 河野正人, 笹倉康佑, 渡邊剛: データセンタの最適マネジメント手法に関する研究 第1報 DCIM の概念と効果について, 日本建築学会大会学術講演会梗概集 2016 年 8 月
- (2) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンタにおける最適マネジメントに関する研究, 空気調和・衛生工学会大会学術講演会論文集(2016.9.14～16)
- (3) 笹倉康佑, 青木健, 渡邊剛: データセンタの最適マネジメント手法に関する研究 第2報 DCIM を活用した ICT 機器の適切な配置位置の決定手法, 日本建築学会大会学術講演会梗概集 2016 年 8 月
- (4) 笹倉康佑, 青木健, 渡邊剛: データセンタの最適マネジメント手法に関する研究 その3 DCIM の情報を活用した温度予測モデルの構築及び評価, 日本建築学会大会学術講演会梗概集 2017 年 7 月 41664
- (5) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンタにおける最適マネジメントに関する研究 (第二報)機械学習を用いたサーバールームの温度予測モデルの構築・評価, 空気調和・衛生工学会大会学術講演会論文集(2017.9.13～15)
- (6) Sasakura, K.; Aoki, T.; Watanabe, T. Temperature-rise suppression techniques during commercial power outages in data centers. In Proceedings of the 2017 IEEE International Telecommunications Energy Conference (INTELEC), Broadbeach, QLD, Australia, 22–26 October 2017.
- (7) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンタにおける最適管理に関する研究 ～ 機械学習を用いたサーバールームの温度予測モデルの構築・評価 ～, 情報通信マネジメント研究会 (ICM) 2018 年 3 月
- (8) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンターの最適管理に関する研究 ～ 機械学習を用いたサーバールームの温度予測の汎用化及び高度化に関する検討及び評価 ～, 情報通信マネジメント研究会 (ICM) 2018 年 7 月
- (9) 笹倉康佑, 青木健, 渡邊剛: データセンタの最適マネジメント手法に関する研究 その4 DCIM の情報を活用した温度予測モデルに関する汎用化の評価, 日本建築学会大会学術講演会梗概集 2018 年 7 月 41321

- (10) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンタにおける最適マネジメントに関する研究
(第三報)サーバールームの温度予測モデルの汎用化及び高度化, 空気調和・衛生工学会大会学術
講演会論文集(2018.9.12~14)
- (11) Sasakura, K.; Aoki, T.; Watanabe, T. Study on the prediction models of temperature and energy by
using dcim and machine learning to support optimal management of data center. In Proceedings of
the ASHRAE Winter Conference 2019, Atlanta, GA, USA, January 2019.
- (12) 笹倉康佑, 青木健, 渡邊剛: データセンタの最適マネジメント手法に関する研究 その5 空調停止
後のサーバールームにおける温度変化に関する DCIM と機械学習を用いた予測モデルの検証, 日本
建築学会大会学術講演会梗概集 2019 年 7 月 41577
- (13) 笹倉康佑, 青木健, 渡邊剛: DCIM を用いたデータセンタにおける最適マネジメントに関する研究
(第四報) サーバルームの温度予測モデルの高度化, 空気調和・衛生工学会大会学術講演会論文
集(2019.9.18~20)