

# MINDデータセンターの カーボンニュートラルへの挑戦

Challenges to Carbon Neutral for MIND Data Centers

長谷川 治\*  
Osamu Hasegawa  
飯塚 剛\*  
Tsuyoshi Iizuka  
馬場 航\*  
Wataru Baba

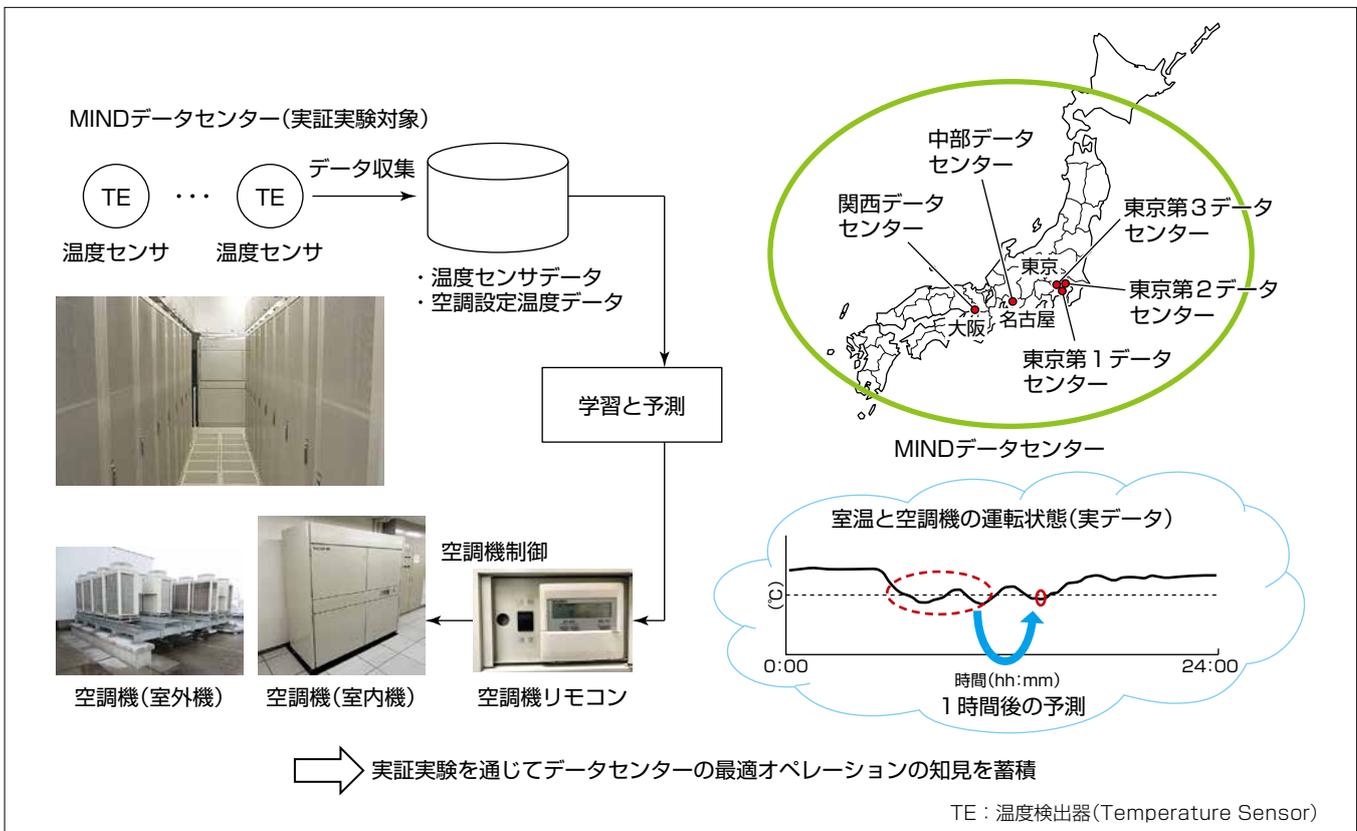
穂苅寛光†  
Hiroaki Hokari  
中根滉稀†  
Koki Nakane

## 要 旨

政府は2050年までに温室効果ガスの排出を全体としてゼロにする脱炭素社会の実現を目指すことを宣言した。地球温暖化対策は全世界的な課題であり、研究開発や規制改革など、その対応が広く求められている。三菱電機インフォメーションネットワーク株式会社(MIND)では、一般的に電力消費が大きいと言われるデータセンターを東京に3か所、名古屋、大阪に各1か所の計5か所で運営しており、日々の運用で省エネルギーを推進している。省エネルギーの中心になるのはサーバ室の空調温度最適化である。サーバ機器は24時間365日稼働が前提であるが、温度異常はサーバ停止に直結するため、サーバ室の温度管理はオペレータの経験や技術に頼らざるを得なかった。

そこで、MINDが保有・運用するデータセンターの空調制御に関するノウハウに、三菱電機のAI技術を適用した“AI技術を活用した空調制御実証”を東京第2データセンターで行った。実証実験では各空調機の設定温度を変更した際の将来(1時間後)の室温変化を出力するAI(予測)モデルを作成して使用した。1時間後の室温が管理上限に近づく設定温度を予測することで、管理上限を長時間超えない範囲で空調機の設定温度を上げることが可能になり、省エネルギーに結び付けることができた。

この実証結果を基に、実稼働に向けての開発を推進するとともに他のデータセンターへの適用を行い、更なる省エネルギーを進めていく。



## MINDデータセンターでのAI活用による空調機消費電力削減の取組み

三菱電機のAI技術“Maisart”を適用し、MINDデータセンターの空調の省エネルギー制御に取り組む。今回、AIによる室温予測モデルを作り、その予測を基に空調機を制御する実証実験を行った。

## 1. ま え が き

世界的に地球温暖化対策が注目される中、2020年10月に政府は2050年までに温室効果ガスの排出を全体としてゼロにする脱炭素社会の実現を目指すことを宣言した。2021年4月に開催された気候変動に関する首脳会議で、2030年までに温室効果ガスを2013年度比で46%削減する新目標を表明する動きもあり、脱炭素、すなわちカーボンニュートラル(CN)に向けた対応を加速させる必要がある。

“情報化社会の進展がエネルギー消費に与える影響”<sup>(1)</sup>によれば、世界全体の年間消費エネルギーの2%(476TWh)、国内の年間使用電力量の1%(9.9TWh)がデータセンターで消費されていると言われている。MIND東京第2データセンターは2020年度実績で年間約2,400kWh/m<sup>2</sup>の電力を消費しており、建物用途別年間電力需要(kWh/m<sup>2</sup>)の比較では、一般的に消費電力が多いと言われる商業施設と比べて、8倍程度の電力を消費している<sup>(2)</sup>(図1)。このため、データセンターでの省エネルギーはCNの実現に大きく貢献できると考えられる。

## 2. MINDデータセンターでの消費電力量削減の取組み

### 2.1 これまでの消費電力削減の取組みと課題

MINDは1999年11月に東京第1データセンターを開設し、以降東京第2、中部、関西、東京第3と拡張し、20年以上にわたってデータセンターを運用している。表1に示すように過去様々な省エネルギー対策に取り組んできたが、サーバ機器の高性能化に伴う消費電力の増大と、これを冷却する空調負荷の増大に伴い、省エネルギーは大きな課題になっている。

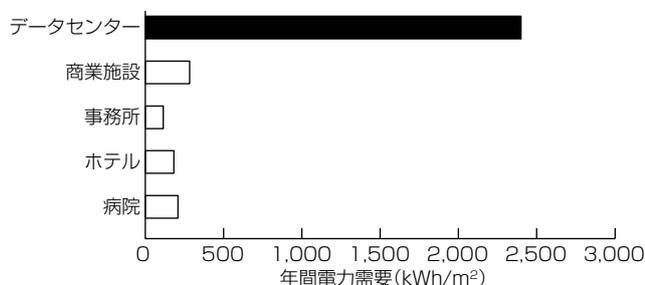


図1. 各種施設の年間電力需要比較

表1. 分野別の省エネルギー取組み項目

分野	主な取組み
建築	天井裏レターン(給排気分離)、垂れ壁・通風板の導入
電気	高効率機器の採用、照明消灯
機械	空調機の稼働台数削減、サーバ室の排熱利用(加温)

データセンターの電力は、大きくサーバなどICT(Information and Communication Technology)機器と空調設備機器とに分類できる。ICT機器は大半が顧客資産であり、利用方法も顧客ごとに異なるためMINDが主導して省エネルギーを行うことが困難である。

一方、空調設備機器は所定の室内環境を維持することを前提に制御可能であるため、高効率機器の導入に加えて、運転台数の削減、設定温度変更による省エネルギーが可能である。しかし、24時間365日、サーバ室の環境を適正値に保ちながら人手を介して台数変更や温度設定を行うことは困難であるため、余裕を持った運転台数と設定温度で運用してきた。更なる省エネルギーにはきめ細かな運転計画と自動制御が必要であるため、2019年5月から2021年3月までAI技術を活用した空調制御実証を東京第2データセンターで行ったので、その結果と今後の展望について述べる。

## 3. AIを活用した消費電力削減の実証

MINDが保有・運用するデータセンターの空調制御に、三菱電機のAI技術“Maisart”を適用し、空調の省エネルギー制御を目指す。従来は人の経験則によって空調制御を行っていたが、AI導入によって人手や立ち上げ期間を削減することが可能になる。今回、AIによる室温予測モデルを作って、その予測を基に空調機を制御する実証実験を行った。

### 3.1 アプローチ

実証実験は、既存のデータセンターを対象に、サーバ室の室温分布等から省エネルギーの実現可能性を確認するための次の三つのステップから成る(図2)。

#### (1) 現状把握

サーバ室内のラック前温度をきめ細かく収集できるように、この実証実験用として温度センサを38台追加して測定した(図3)。その結果、サーバ室の室温管理値(室温上限)より余裕がある(冷やしすぎ)箇所が見つかった。現状、各空調機の稼働状況や風量、吹き出し温度は固定設定だが、これを調整できれば空調機の消費電力を減らす余地があることが判明した。

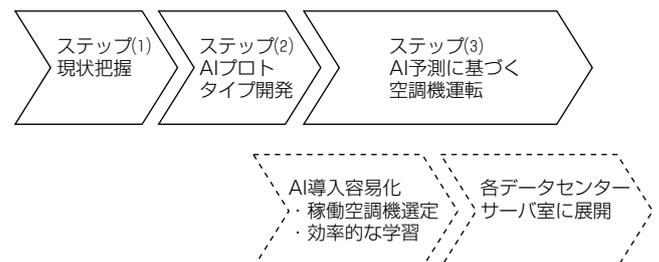


図2. 実証実験でのステップ

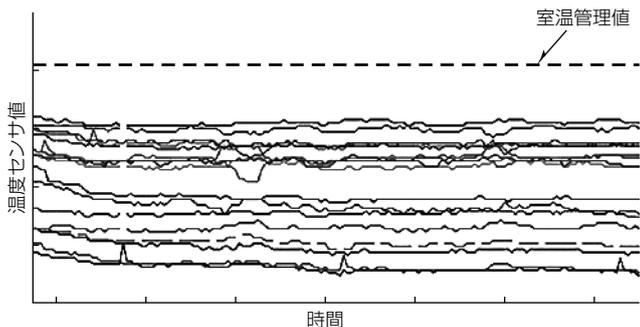


図3. AI導入前のラック前温度(例)

(2) AIプロトタイプ開発

AIを用いた空調制御の学習は研究が進められており、教師あり学習を用いたもの、教師なし学習を用いたもの、強化学習を用いたものと様々な手法が存在する<sup>(3)</sup>。近年は深層強化学習を用いたもの<sup>(4)</sup>や、MPC(Model-Predictive Control)<sup>(5)</sup>を取り入れた研究も報告されているが、これらの学習には多くのデータ量を要する場合や、データセンターのシミュレータが必要な場合がある。既存の多種多様なデータセンターにAIを適用する場合は現場ごとに収集できるデータ量で学習が可能な方式を選定する必要がある。

AIプロトタイプ開発では、各空調機の設定温度を変更した際の将来(1時間後)の室温変化を出力するAI(予測)モデルを、教師あり学習を用いて作成した。制御時はそれを用いて、室温管理値を超えない範囲で、空調機の設定温度を最大化するよう制御することで省エネルギーを実現する(図4)。事前に、各空調機の設定温度を変化させた際の温度センサのデータを収集し、それを教師データとして予測モデルの学習を行った。予測モデルの入力データは、各温度センサの観測温度、現在と設定温度変更後の稼働室内機の設定温度とした。なお、今回のデータセンターはラックの消費電力変動が少ないことに加えて、ラック消費電力と室温に強い相関が見られなかったため、ラック消費電力を入力データに加えなかった。センサの精度や気流の影響による外乱も加味し、予測モデルの精度目標は誤差0.5℃にした。

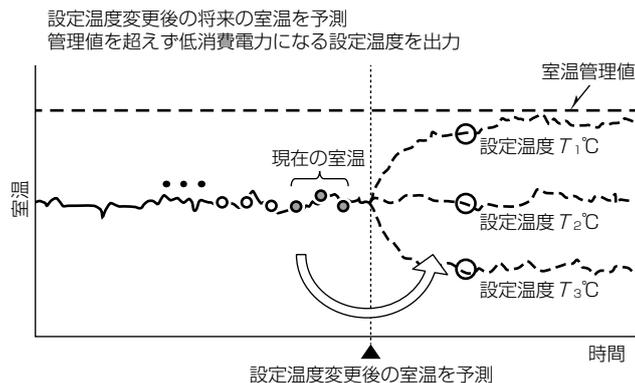


図4. AIによる室温予測

(3) AI予測に基づく空調機運転

作成した予測モデルを用いて、室温が管理値に近づくように1時間後の温度を予測しつつ、1時間に1回データセンターの各空調機の設定温度を変更する実証試験を行った。その結果、ラック前温度が室温管理値を長時間超えない範囲で空調機の設定温度を上げることが可能になった(図5)。なお、空調機の設定温度は時間によってある程度変動するものの、基本的には空調機ごとに、それぞれ同じ設定温度に収束する傾向を示した。

3.2 成果

空調機の設定温度調整によって、1台当たり平均1.3℃設定温度を増加させることができた。今回の実証試験を行ったデータセンターでは人の経験に基づいて空調機の稼働台数が既に削減されていたが、削減前の全台稼働状態と比較すると、32%省エネルギー(室外機15%削減、室内機49%削減)になった。稼働空調機の削減自動化については、3.3節で述べる。また、実証試験での予測モデルの将来設定温度の予測誤差は平均0.34℃と目標値以内になった。

3.3 本格運用に向けた課題

この手法の成果をMINDの各データセンターに展開して省エネルギー効果を拡大するには、それに要する人手や期間を減らすことが必要になる。AIによる空調制御をデータセンターに導入する際の稼働空調機の選定と、学習に要する人手と期間を減らすための効率的な学習が課題である(図6)。

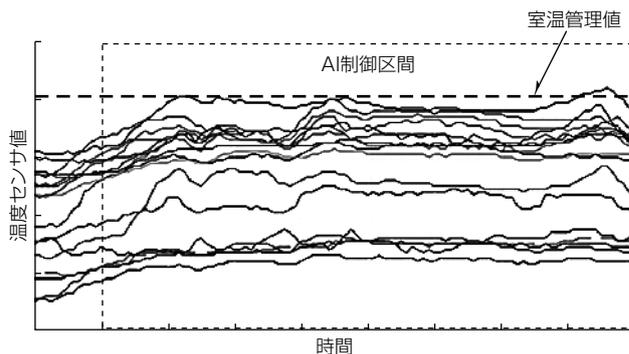


図5. AI導入後のラック前温度(例)

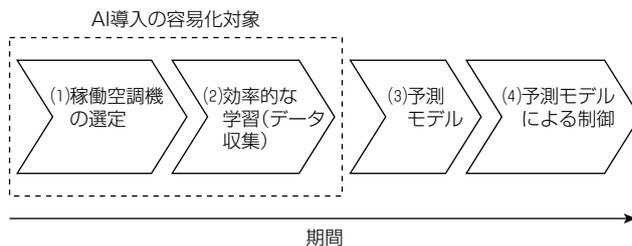


図6. AIによる空調制御の導入容易化

### (1) 稼働空調機の選定

従来、既存のデータセンターでは、ラックやサーバ等の発熱源や空調機配置等の条件から、人の経験と試行錯誤で稼働させるべき空調機を選定していた。稼働空調機を選定する条件はデータセンターのサーバ室ごとに異なるため一般化が難しい。AIでサーバ室の条件に応じた稼働空調機の選定ができれば、多くのサーバ室への導入を容易にでき、大きな省エネルギー効果を見込むことができる。

### (2) 効率的な学習

サーバ室の室温分布に対する空調機の温度設定の相関を学習するには、膨大な組合せの数のデータが必要になる。学習データを減らす効率的な学習ができれば、AIによる空調制御を導入するために必要な期間を短縮できる。

#### アクティブラーニング

元来は膨大なラベルなしデータに対して、どのデータにラベル付けすればAIエンジンの精度が最も良くなるかを決定する機械学習手法

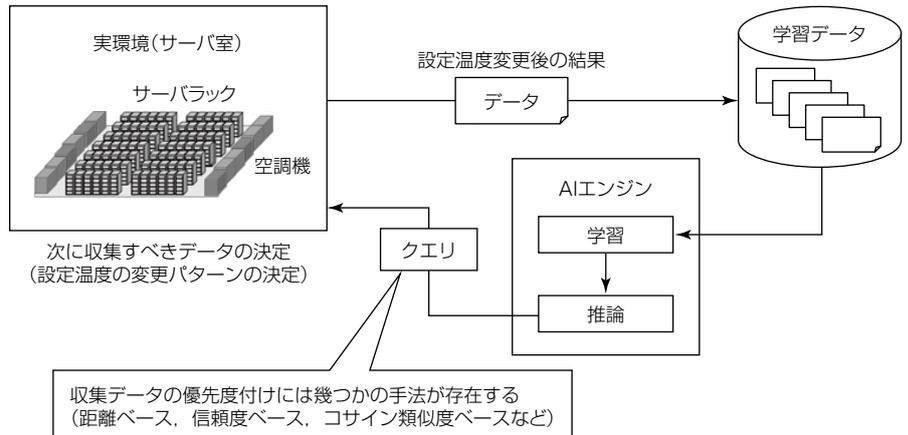


図7. アクティブラーニング

データ収集効率化を図るものである(図7)。

今回、机上試験で7手法のマトリクスを検証し、有用な手法を絞り込んだ。実証試験で有用な手法を評価したところ、従来と比較して1/3程度のデータ収集量で予測モデルの学習が可能なることを確認した。

## 4. 課題解決に向けた技術開発

### 4.1 最適な稼働空調機の探索

稼働空調機の組合せは多いため、サーバ室で全ての組合せを試すことは難しい。そのため、最小限の稼働空調機パターンで組合せを試す。得られたデータを教師データとして、稼働空調機パターンに対するセンサ温度を予測するモデルを学習し、それをを用いて最適な稼働空調機のパターンを探索する方式を開発した。これによって実機での探索回数を大幅に削減可能である。なお、方式が有効に働くにはモデルの推論精度が一定範囲内である必要がある。検証のため、データセンター内の室温のふるまいを模したシミュレータを作成し、モデルの予測精度の検証を実施した。その結果、実環境換算で約3週間分のデータ数で推論精度が平均1℃になり、探索にモデルを活用できることを確認した。

### 4.2 アクティブラーニングによる自動学習

アクティブラーニングは大量にあるラベルなしのデータから、ラベルを付与すれば性能向上につながるデータを効率的に選ぶ手法であり、主に画像や言語分野のアノテーション(人手のラベル付与)効率化に用いられる<sup>(6)</sup>。今回その手法をデータセンターのデータ取得に適用した。実環境から収集したデータで予測モデルを学習する際、次に収集すべきデータ(稼働空調機の設定温度の組合せ)を予測モデル自身があるマトリクスを基に優先度付けすることで、

## 5. むすび

現在AIを活用した空調制御は東京第2データセンターでの実運用に向けた開発を進めているが、このシステムは設備機器に依存しないことから他のデータセンターへの展開も可能であり、実現できればデータセンター全体で大きな省エネルギーが期待できる。一方、CNの実現には省エネルギーに加えて再生可能エネルギーの導入が必要になるが、既設データセンターへの導入には設置場所やコスト面での課題も多い。今後、新築データセンターではCNを意識した建築・設備設計も必要と考えており、MINDデータセンターではCNの実現に向けて、今後も省エネルギーを中心に運用改善に挑戦し続けていく。

### 参考文献

- (1) 国立研究開発法人 科学技術振興機構 低炭素社会戦略センター：情報化社会の進展がエネルギー消費に与える影響(Vol.1) —IT機器の消費電力の現状と将来予測— (2019) <https://www.jst.go.jp/lcs/pdf/fy2018-pp-15.pdf>
- (2) 空調調和・衛生工学会：都市ガスコージェネレーションの計画・設計と運用、丸善出版 (2015)
- (3) Dayarathna, M., et al.: Data Center Energy Consumption Modeling: A Survey, IEEE Communications Surveys & Tutorials (2015)
- (4) Li, Y., et al.: Transforming Cooling Optimization for Green DataCenter via Deep Reinforcement Learning, IEEE Transactions on Cybernetics (2019)
- (5) Lasic, N., et al.: Data center cooling using model-predictive control, NeurIPS (2018)
- (6) Settles, B.: Active Learning Literature Survey (2010)