

博士論文

次世代 BEMS に向けた空調用熱源システムの
不具合検知・診断と最適制御に関する研究

宮田 翔平

博士論文

次世代 BEMS に向けた空調用熱源システムの
不具合検知・診断と最適制御に関する研究

令和 2 年 3 月

東京大学大学院工学系研究科建築学専攻

宮田 翔平

Dissertation

Fault Detection and Diagnosis and Control Optimization
for Heat Source Systems
toward the Next-Generation BEMS

March 2020

The University of Tokyo

School of Engineering, Department of Architecture

Shohei Miyata

要旨

本論文は、熱源システムの高効率な運用を支援する次世代 Building and Energy Management System (BEMS) の実現に向けて遂行された不具合検知・診断と最適制御に関する検討についてまとめたものであり、以下の 8 章からなる。

第 1 章では、持続可能な開発目標 (SDGs) の採択やパリ協定の発効といった社会情勢の中で業務用建築物、特にその空調用熱源システムの低炭素化や高効率な運用の重要性について述べた。しかし、空調システムは不具合と呼ばれるエネルギー効率ないしは室内環境を悪化させる要因を有する場合があります、不具合によるエネルギー効率の低下は 5% から 30% にものぼるとの報告もある。不具合の有無を検知し、その種類を診断する不具合検知・診断はこれまで 30 年近くにわたり研究されてきたが、空調システムの固有性や複雑性が原因となり、一般的な手法の開発までは至っていない。また、空調システムの性能をさらに引き出す技術として最適制御が挙げられるが、一般的に実装されているとはいえない状況にある。

空調システムの運用を改善するソフトウェアとして期待される BEMS は、現状としてデータの収集・蓄積や可視化といった機能を有するが、運用改善に直接寄与することはできない。そのため、BEMS の活用には手作業によるデータ分析が必要であるが、データ分析には高度な知識と技能を要するため、従来の BEMS のみではシステムの運用を改善することは難しい。

以上の背景から、蓄積された生データを整理し、欠損値や異常値を処理するデータクレンジング、不具合検知・診断、最適制御、そして検知・診断された不具合を修復する保全計画の立案といった機能を有する BEMS を次世代 BEMS として示した。本論ではこのうち喫緊の課題として不具合検知・診断と最適制御に関する検討を行うことを目的として示した。

この目的を達成するための手法として、熱源システムの詳細なシミュレーションプログラムと、深層学習やモデル予測制御といったアルゴリズムを活用することを述べた。本論では蓄熱槽を有する事務所 A と、よりシンプルな工場 B の熱源システムを対象とした。なお、システムが不具合を有さない状態を最適状態ともみなすことができるため、不具合検知・診断と最適制御は表裏一体の関係にあることも留意すべき点として示した。ただし、本論では不具合検知・診断と最適制御をそれぞれ別の課題として解くために、不具合を有さない状態を設計時の想定に基づく状態とした。

第 2 章では、BEMS データを手作業で分析した結果を示した。事務所 A と工場 B の双方において不具合がみられ、現実のシステムにおける運用実態を示した。不具合の例としては機器性能低下、設定値不全、下限値不全が診断された。一連の分析には、機器特性や物理モデルに基づいた性能指標の算出や、制御ロジックに基づいた適切な制御状態の想定が必要であることを示した。

第 3 章では、不具合検知・診断や最適制御の検討に用いる詳細なシステムシミュレーションプログラムについて記述した。不具合検知・診断や最適制御には、不具合が生じた場合や設定値が変更された場合の機器制御や温度・流量といったシステム挙動データが必要であ

る。そのため、負荷や外気湿球温度といった境界条件に加え、設定値や不具合条件に応じてシステム挙動を適切に表現可能なシミュレーションプログラムを構築した。具体的には、機器性能曲線、熱交換器や流量計算に関する物理モデル、(proportional integral) PI 制御等のフィードバック制御を組み込んだシミュレーションプログラムを作成し、制御の過渡状態を算出可能とした。

第4章ではまず、不具合検知・診断のスキームとして、最初に不具合の有無そのものを検知し、次にどの種類の不具合が生じているかを診断し、最後に診断された不具合の程度を同定することで不具合の修復効果を定量化することを示した。本論ではこのうち不具合検知と診断が検討対象である。

次に、熱源システムの計測・制御における真値との誤差を本論における不確かさとして定義・モデル化し、それをシミュレーションプログラムに組み込むことで、System Coefficient of Performance (SCOP) 分布（性能分布）を算出した。この性能分布の信頼区間外、性能が低い側に BEMS データが位置した場合、対象システムにおいて SCOP に大きな影響を与える不具合が存在すると判断でき、不具合検知が可能であることを示した。

第5章では、深層学習の一手法である畳み込みニューラルネットワークを用いた不具合検知・診断の準備として、システムシミュレーションによる不具合データベースの作成を行った。設定値不全や機器性能低下、センサ誤差といった不具合条件をシミュレーションプログラムに組み込むことで、システムが不具合を有する場合の挙動を算出した。また、学習に用いた畳み込みのニューラルネットワークの特徴についても記述した。

第6章では、畳み込みニューラルネットワークに不具合データベースを与え、不具合の特徴を学習させた。そして BEMS データを学習済みネットワークに入力することで、BEMS データがシミュレーションで想定された不具合のうち、どの不具合の特徴がみられるか確率をもって診断可能とした。本手法は不具合の想定とシミュレーションの実行という労力が必要であるが、人がデータを詳細に分析する必要がなくなるという点で有用であり、将来的にシミュレーション構築も Building Information Modelling (BIM) の発展等により自動化されることが想定されている。

第7章では、モデル予測制御による低炭素制御に取り組んだ。まず1時間ごとの二酸化炭素排出係数 $[\text{kg-CO}_2/\text{kWh}]$ を推定し、これをもとに二酸化炭素排出量が最小となる制御を行った。具体的には蓄熱槽を調整力として有する事務所 A の熱源システムを対象とし、冷凍機の発停をモデル予測制御によって決定した。その結果、計算対象期間とした6月の1週間において、従来の夜間蓄熱や昼間蓄熱に対してそれぞれ47%、13%の二酸化炭素排出量削減効果が得られた。また、予測負荷における正負10%の誤差に対しても削減効果は得られたため、本手法は有効であることが示された。

第8章では本論文の総括を行った。また、今後の課題として、生データを利用可能な状態に成形するデータクレンジング手法の開発、熱源システムから空調システム全体への検討対象の拡張、シミュレーションプログラムの完全動的化、不確かさについての実態把握、不

具合検知・診断手法の実装に向けた学習効率化, 保全計画立案とそのための不具合の程度同定, 低炭素制御による電力系統への寄与としての再生可能エネルギー導入拡大量の推定を挙げた。

Abstract

This dissertation is the summary of the research for fault detection and diagnosis and control optimization toward the next generation building and energy management system (BEMS) that support efficient operation of heat source systems which are so called cooling and heating plants of heating, ventilation and air conditioning (HVAC) systems. The dissertation consists of the following eight chapters.

In the chapter one, the importance of low carbonization and efficient operation of commercial buildings, especially their heat source systems under the context of sustainable development goals and the Paris Agreement. However, HVAC system has faults that deteriorate energy efficiency or worsen the indoor environment. Some literature reports that the energy efficiency reduction is from 5% to 30%. Although fault detection and diagnosis (FDD) that detects the existence of faults and diagnoses the type of faults has been researched for nearly 30 years, general methods have not been developed because of the inherence and complexity of HVAC systems. In addition, control optimization is also a technology that brings out the potential of HVAC systems, however, it is not common to install the control optimization into the real system.

BEMS is a software that has been expected to improve the operation of a HVAC system. Although it has functions such as data collection, storage, and visualization, they cannot contribute the improvement directly. Therefore, to utilize the conventional BEMS, manual data analysis that requires expert knowledge and calculation ability is necessary.

Considering above, the next generation BEMS whose functions are data cleansing that processes missing and abnormal values, FDD, control optimization, and planning of maintenance for eliminating faults has been proposed. In the dissertation, FDD and control optimization were set to objectives as the urgent issues.

The methodologies to achieve the objectives were described as the utilization of detailed simulation programs of heat source systems and algorithms such as deep learning and model predictive control (MPC). In the dissertation, the target systems were two heat source systems: one is in Office A that has water heat storage tanks and the other is in Factory B that is simpler than Office A. It should be noted that FDD and control optimization can be regarded that the two sides of the same coin because a system without faults can be regarded as optimal condition. In the dissertation, the condition based on the design was regarded as a condition without faults to distinguish FDD and control optimization as independent issues.

In the chapter two, BEMS data was analyzed manually. Faults were diagnosed in both Office A and Factory B, and the real operation of heat source system was clarified. For example, equipment deterioration, inappropriate set values, and inappropriate lower limits were diagnosed. The analysis required calculating performance indices based on equipment characteristics and physical models and assuming control behavior based on the control logics.

In the chapter three, the detailed system simulation programs that were utilized for FDD and control optimization were described. FDD and control optimization require system behavior data such as equipment control, flow and temperature, in the case of changing set values and occurring faults. Therefore, the simulation programs were coded so that they can express system behavior appropriately based on set values and fault conditions in addition to the boundary conditions such as heat load and outdoor wet bulb temperature. In concrete, equipment performance curves, physical models for heat exchanger and flow calculation, and feedback control such as (proportional integral) PI control were incorporated into the simulation program, which enabled to calculate control transient status of the heat source systems.

In the chapter four, at first, FDD scheme that includes detecting the existence of faults, diagnosing the types of faults, and identifying the severities of diagnosed faults that enables to quantify the effect of eliminating the faults. In the dissertation, detecting and diagnosing faults are targeted.

Then, distributions of system coefficient of performance (SCOP) were calculated by modelling and incorporating uncertainties which is defined in the dissertation as errors against true values in measurement and control in heat source systems. The distribution can detect faults that influence system performance seriously when the BEMS data locates the lower side of the confidential interval of the distribution.

In the chapter five, fault database was generated as a preparation for the FDD method that utilized convolutional neural networks (CNNs) which is one of the deep learning algorithms. Fault conditions such as inappropriate set values, equipment deterioration, and sensor errors were incorporated into the simulation program and the faulty behaviors were calculated. In addition, the characteristics of the CNNs utilized for the learning were described.

In the chapter six, the CNNs learnt the feature of faults from the fault database. Then, the BEMS data was given to the trained CNNs. The CNNs diagnosed probabilities that express the features of which faults were observed in the BEMS data. The proposed method requires assuming fault types and implementing simulations to generate fault database, however, it has advantages in less manual data analysis, and it is expected to implement the simulation automatically thanks to the development of building information modeling (BIM).

In the chapter seven, MPC was applied for the low carbonization control. First, the coefficient of carbon dioxide emissions [$\text{kg-CO}_2/\text{kWh}$] was estimated, and then the heat source system was controlled to achieve minimum CO_2 emissions based on the coefficient. In concrete, the target was the heat source system in Office A that has water heat storage tanks as energy buffer, and refrigerators were controlled by MPC. As a result of case studies whose period was a week in July, the proposed method reduced CO_2 emissions against conventional nighttime storage and daytime storage by 47% and 13% respectively. In addition, the reductions were also achieved in the cases that the load prediction has 10% positive and negative error, which indicates the effectiveness of the proposed

method.

In the chapter eight, the dissertation was summarized. In addition, the further considerations were listed as data cleansing that processes the raw data to available data, expansion of target from heat source system to HVAC system, upgrade of simulation programs to fully dynamic model, search for uncertainty in the real operations, more efficient learning of CNNs to install the proposed FDD method to a real BEMS, identification of diagnosed faults that leads planning of maintenance, and estimation of the amount of renewable energy that can be introduced by the proposed control method.

目次

第 1 章 序論	1
1.1. 本論文の背景	2
1.2. 次世代 BEMS の提案	5
1.3. 本論文の目的	8
1.4. 不具合検知・診断と最適制御	9
1.5. 研究手法と本論文の構成	11
第 2 章 BEMS データ分析	17
2.1 事務所 A	18
2.2. 工場 B	39
2.3. データ分析によって診断された不具合	54
2.4. 小括	55
第 3 章 熱源システムシミュレーションプログラム構築	57
3.1. 本章の背景と目的	58
3.2. 機器モデル	64
3.3. 水搬送系モデル	76
3.4. 制御モデル	80
3.5. システムモデル	83
3.6. 計算結果例	85
3.7. 小括	86
第 4 章 不確かさを考慮した不具合検知	89
4.1. 本章の背景と目的	90
4.2. 不具合検知・診断のスキーム	93
4.3. 不確かさのモデル化	95
4.4. 不確かさを考慮した性能分布の算出と不具合検知	99
4.5. 計算回数に関する一考察	107
4.6. 今後の課題	110
4.7. 小括	111

第 5 章 不具合検知・診断—背景・目的と手法	117
5.1. 本章・次章の背景と目的	118
5.2. 不具合データベースの作成	122
5.3. データ前処理	129
5.4. 畳み込みニューラルネットワーク (CNNs)	133
5.5. 小括	139
第 6 章 不具合検知・診断—結果と考察	143
6.1. CNNs の学習結果	144
6.2. BEMS データ診断結果	152
6.3. 考察と今後の課題	167
6.4. 小括	169
第 7 章 最適制御	173
7.1. 本章の背景と目的	174
7.2. 動的二酸化炭素排出係数の推定	176
7.3. 従来制御	180
7.4. Carbon Activated Demand Response (CADR)	181
7.5. 結果	187
7.6. 考察と今後の課題	194
7.7. 小括	195
第 8 章 総論	201
8.1. 本研究で得られた成果	202
8.2. 本研究の課題と展望	204
謝辞	207

第1章

序論

1.1. 本論文の背景

2015 年 9 月に国連サミットにて持続可能な開発目標（SDGs）が採択され、翌 2016 年 11 月に気候変動枠組条約締約国会議（COP21）で採択されたパリ協定が発効した。ESG 投資や環境投資等の言葉も盛んに用いられ、近年は持続可能性という観点を中心に地球温暖化や生態系保全等の重要度が高く認識されている。パリ協定では具体的な数値目標が国ごとに定められ、日本も約束草案に 2030 年度に二酸化炭素排出量を 2013 年度比で 26%減とすることを目標として提出している[1]。この目標を達成するためには電力需要側における 17% に上る徹底した省エネと、電源側における 22~24%もの再生可能エネルギー導入が必要とされる[2]。特に、オフィスビルが含まれる業務その他部門は約 4 割もの削減が目標値として定められており、他部門と比べてもその達成は容易ではない（Fig. 1-1）。




Fig. 1-1 CO₂ emissions in each sector and goal for commercial sector, depicted based on [3] [4]

この状況の中で、米国、EU、日本といった先進国における建築物のエネルギー消費は最終エネルギー消費の約 40%を占め、二酸化炭素排出量に関しては全体の約 30%を占める[5]。建築物のうち、Commercial sector または業務他部門に限ると、世界全体の最終エネルギー消費における割合は 7%に留まるが、アメリカ、イギリス、日本ではそれぞれ 18%、11%、16%を占める[6][7]。Commercial sector または業務他部門に含まれるオフィスビルに関しては、空調システム（Heating, Ventilation and Air Conditioning System, HVAC system）はそのエネルギー消費においてアメリカ、イギリス、の順に 48%、55%、48%を占める[6]。さらに、IEA（International Energy Agency）の報告では非住宅部門における冷房設備能力は 2050 年には 2016 年比で 60%から 85%増加するとの試算もある[8]。以上より、業務用建築物の空調システムは世界的にみても最終エネルギー消費に占める割合が大きく、将来的なエネルギー消費量の増加も見込まれることから、その効率改善や効果的な運用は世界的な社会的意義が非常に大きい。

空調システムのエネルギー効率を向上させるためには、設計、施工、運用段階において最善を尽くすことが必要である。設計段階の例として、機器選定・運転の最適化やダクト形状の最適化手法が提案されている[9] [10] [11]。このように設計段階の最適化では対象建物に対して予想される負荷を定め、冷凍機やポンプ、冷却塔の容量と機器の効率を最大化する制御手法を提案することが求められる。しかし、設計と施工後のシステムのギャップ、居住者の利用方法や外気条件など設計時に予測が難しい要素が多いため、制御手法は運用開始後に改めて最適化検討を行うことが本来は望ましい。

施工段階では、Value Engineering（コストカット）による低い性能の機器導入を抑え、設計時の意図を最大限反映した施工が求められる。施工を効率化するツールとして、Building Information Modelling（BIM）が近年利用されるようになり、ライフサイクルでのエネルギー効率の検討にも研究段階ではあるが用いられるようになってきた[12] [13][14]。しかし、センサ取り付け位置や配管の接続が不適切であるゆえに制御不全が生じる場合もあり、課題は依然として残っている。

運用段階においては、最適制御が当然必要ではあるが、その前に不具合に対して適切な対処を行うことが求められる。空調システムにおける不具合（fault）とは、システム本来の性能発揮を阻害する要因であり、室内空気環境の悪化やエネルギー効率の低下を引き起こすものと定義される[15]。不具合の例としては機器の性能劣化、不適切な設定値、センサ誤差が挙げられる。これら不具合によって、空調システムは 5%から 30%もの効率低下が生じていると言われる[16] [17] [18]。

空調システムにおける不具合の存在の有無を検知し、その原因を特定すること（不具合検知・診断、Fault Detection and Diagnosis, FDD）はその重要性ゆえに約 30 年前から研究が行われている。最も初期に集中的になされたのが 1991 年から開始された Annex 25（Annex: International Energy Agency（IEA）の一部会である Energy in Buildings and Communities Programme（EBC）における国際研究委員会）であり[19][15]、その後 2001 年にも ASHRAE

にてシンポジウムが開催されている[20] [21] [22] [23]。これらの研究を端緒として現在に至るまで多くの検討が行われており[24] [25] [26] [27] [28]，現在は実装に向けて Lawrence Berkeley National Laboratory (LBNL) や National Institute of Standards and Technology (NIST) などにおいて実証研究が進められている[29] [30]。しかし，これらのプロジェクトは手法の開発，データの収集から始められており，現時点で一般的な手法が確立されたとは言えない。

最適制御に関しては，PID 制御パラメータや温度等の制御パラメータの最適値探索[31] [32]をはじめとして，蓄熱槽や蓄電池の運転最適化[33] [34] [35] [36]がこれまで検討されてきた。さらに近年は化学プラント等で利用されていたモデル予測制御 (Model Predictive Control, MPC) の空調システムへの適用が研究されている[37] [38]。

なお，FDD の概念を包含する実務的プロセスとしてコミッショニング (Commissioning, Cx) が近年普及し始めている[39]。Cx とは，Annex 40 にて以下のように定義されている[40]。

Clarifying building system performance requirements set by the owner, auditing different judgments and actions by the commissioning related parties in order to realize the performance, writing necessary and sufficient documentation, and verifying that the system enables proper operation and maintenance through functional performance testing. Commissioning should be applied through the whole life of the building.

Cx は建築物が求められる性能を発揮するために必要なプロセスであり，その対象は空調システムに留まらず外皮などにも及ぶ[41]。そのため，FDD や最適制御は Cx プロセスにおける要素技術として採用または活用が期待されるものである。

1.2. 次世代 BEMS の提案

1.2.1. 現在の BEMS 構成

従来の BEMS では、現場のコントローラが計測値を Building Automation System (BAS) に送信し、BAS はそのデータを一時的に Web サーバへ受け渡す (Fig. 1-2)。BAS によって演算された設定値が現場のコントローラにフィードバックされる場合もある。BAS の Web サーバは現在時刻のデータを留めるのみでデータ保存機能は有さないため、クラウド上のデータベース (DB) にデータが蓄積される。

Energy Management System (EMS) は、DB に保存されたデータを抽出し、エネルギー消費効率計算といった演算処理を行い Web サーバへ値を受け渡す。このデータはグラフ化に用いられる。演算処理が行われたデータが DB に保存される場合もある。

モニター画面上では、BAS を通した現在運転状況の把握と、EMS を通した運転実績のグラフを確認することができる。BAS は主にリアルタイムの情報管理を担当しており、冷凍機の異常といった警報を発するシステムが既に存在する。

FDD や最適制御を建築物に適用するためには、ハードウェアである設備そのものに対して、ソフトウェアである Building and Energy Management System (BEMS) に各手法をインストールすることが想定される。しかし、現状の一般的な BEMS の主な機能はデータの可視化（見える化）にとどまっている。そのため、従来の BEMS は導入のみで省エネ化や低炭素化を望めるものではなく、可視化されたデータを分析し、その対策を実行可能な人材がいることで初めて運用改善が可能となる。

なお、BEMS と呼ばれるものには EMS や DB の機能を有さないものも存在する。現在値は現地のモニターで確認できるものの、グラフは描画されず、データは現地の PC に数か月間のみ保存され、分析のためには現地にデータを取りに行く必要がある、といったものである。このような BEMS の導入による省エネ効果を期待することは非常に難しい。

これまで筆者がかかわってきたシステムにおいて、運転管理者の方々はクレーム対応や定期点検・メンテナンス追われ、データ分析まで行うことが時間が確保できない状況であった。さらに、システムは複雑かつ固有であるゆえに現在の設定値が最適であるか把握しきれておらず、居住者からのクレームが来ない限りは設定値を変更することができないという状況もあった。そのため、エネルギー効率の向上を志向するには人手が不足し、結果として居住者からのクレームが出ないよう日々努める現状となっていると考えられる。

以上を踏まえると、DB 上で保存された過去の運転データを用い、不具合検知・診断や最適制御といったアルゴリズムが BEMS 上で実行されることが省力化のためには有効であると考えられる。

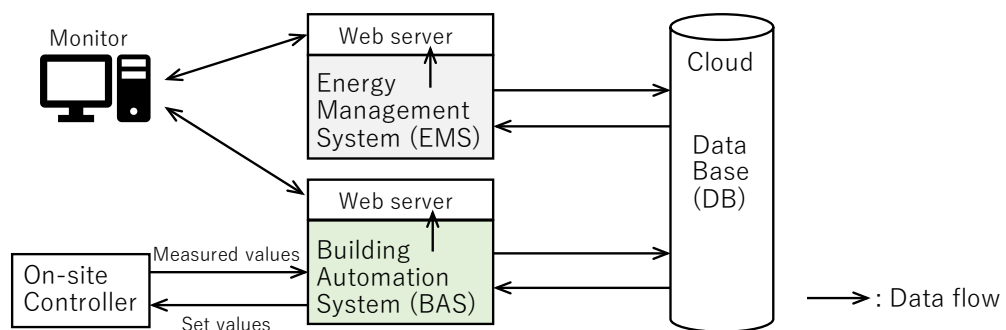


Fig. 1-2 Structure of a conventional BEMS

1.2.2. 提案する次世代 BEMS

そこで、DB に蓄積されたデータを活用するアルゴリズムやプログラムを有する BEMS を次世代 BEMS として提案する (Fig. 1-3)。次世代 BEMS (Next-generation BEMS) は用語としては既出であり[42]、従来の BEMS を改良したものという意味で一般的な用語であるが、具体的な機能として有すべきものを以下に提案する。

具体的なプログラムとして、まず DB 上の生データの異常値や欠損値を処理するデータクレンジング、システム挙動から性能低下の原因を明らかにする不具合検知・診断、最適な設定値や制御手法を探索する最適制御、検知・診断された不具合をもとにした保全計画の立案が挙げられる。本研究ではこれらのうち、不具合検知・診断と最適制御を対象とした。

当然のことではあるが、運用を最適化するためにはシステムが適切に設計されている必要がある。しかし、システムが設計時の想定通りに使われないことや、施工段階において設計時からの変更が生じることは間々ある。そのため、実際に運用が始まっているシステムの性能を最大限に引き出すためには、不具合検知・診断と最適制御を運用時において両方行うことが望ましい。なお、近年は最適制御としてモデル予測制御が注目されている[43]。モデル予測制御は時刻ごとに最適な設定値や制御手法を決定するもので、制約条件は与えるものの詳細な制御ロジックを事前に設計するものではない。空調システムが求められる制御目標が快適性やデマンドレスポンスなど多岐にわたる場合、目標を逐次変更可能であるモデル予測制御は今後活用が期待されるものである。そのため本研究でもモデル予測制御を用いた最適制御の検討を行った。

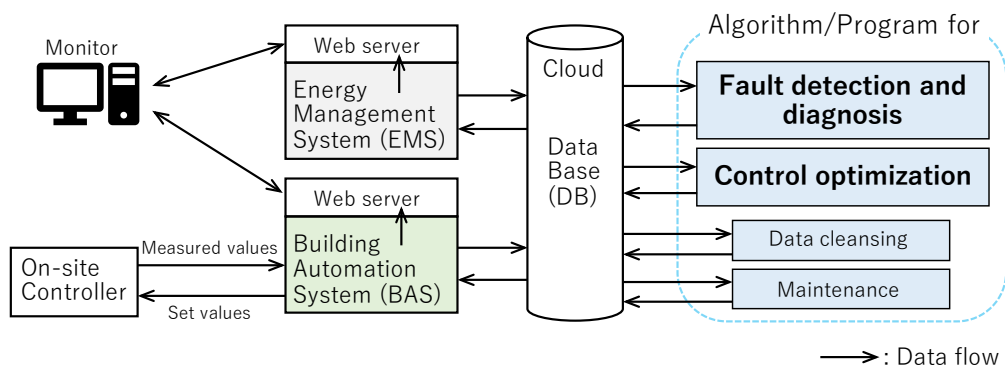


Fig. 1-3 Structure of the next generation BEMS

1.3. 本論文の目的

以上を踏まえ、本研究では空調用熱源システムの高効率な運用を可能とする次世代 BEMS の実現に向け、その機能としての不具合検知・診断と最適化の検討を行うことを目的とした。なお、不具合には配管の接続といったハードウェア構成が原因である場合もあるが、このような種類の不具合は検討対象外とし、何らかの形で診断された場合は知見として最適設計へとフィードバックされるべきだとみなした。

1.4. 不具合検知・診断と最適制御

前述のように、不具合検知・診断と最適制御は空調システムの運用時における最適化の重要な要素である。同時に、両者は表裏一体の関係にある。ここでは前提としてシステムは様々な不具合によって設計時の性能を発揮できていないものとする。そこでまず FDD によりシステムを設計時に想定した性能を発揮できるレベルまで引き上げ、次に制御を最適化することで実際の要求負荷や外気条件といった入力に対してシステムの状態を最適な状態に引き上げることができるはずである (Fig. 1-4)。つまり、不具合検知・診断と最適化は両行われて初めてシステムはそのポテンシャルを発揮できる。

既往文献においても、FDD と最適制御を統合的に扱うシステムを検討した例がみられる [44]。中央式熱源システムを対象として冷却水温度最適化や冷凍機の不具合を検知・診断するものであり、本研究の目指すものと非常に近いが、検知・診断対象の不具合の種類が限定的であることや、制御最適化も従来の設定値最適化が利用されているため改善が可能である。また、FDD と最適化を同時に議論することは先の Annex25 でも行われていた (Fig. 1-5)。まず、Detection (検知) の部分においてエネルギーや室内環境の性能の良し悪しを判定し、“Non-optimal detection”として非最適な設定値も検知する。次に、Diagnosis (診断) によって不具合の原因や箇所を明らかにし、最後に Decisions and Actions (意思決定と対処) として設定値の最適化や不具合の修繕を行うという枠組みが提示されている。

以上を踏まえ、本研究では FDD と最適制御の両者を研究目的とした。なお、不具合を規定する際の基準状態を設計時ではなく最適状態とすると、FDD の概念に最適制御を組み込むことができるが、本研究では問題を切り分けるために不具合がない状態を設計時の性能とし、最適制御によってさらに性能が向上するものとした。




Fig. 1-4 Concept of performance transition of HVAC system

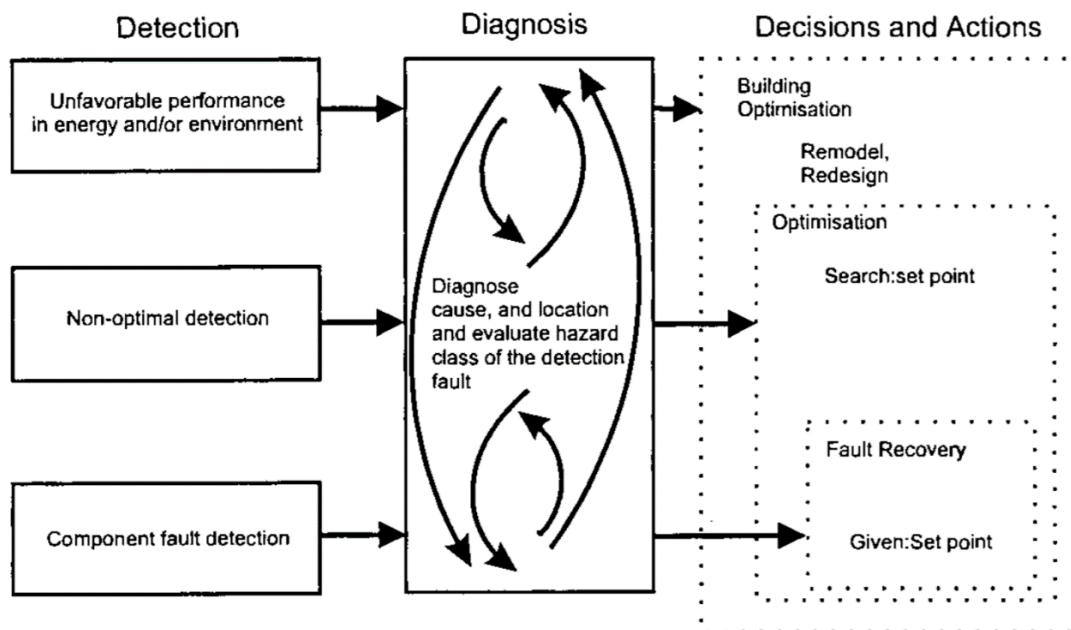


Fig. 1-5 Tasks and Objectives of Building Optimisation and Fault Detection, cited from [19]

1.5. 研究手法と本論文の構成

本論文では上述のように熱源システムにおける不具合検知・診断と最適制御の検討を行うために、蓄熱槽を有するシステム（事務所 A）と有さないシステム（工場 B）の 2 つの実システムを対象に検討を行った。すべての検討は、これらシステムにおける実際の計測データ（BEMS データ）、詳細なシステムシミュレーション、目的を達成するためのアルゴリズムの 3 者を用いて検討を行った。各手法の詳細は各章の記述を参照されたい。

本論の構成として、本章（第 1 章）に続き、第 2 章では BEMS データを手作業で分析した結果を示す。診断した不具合について記述するとともに、BEMS データを適切に分析するために必要な素養を示す。

第 3 章では不具合検知・診断や最適制御の検討に用いる詳細なシステムシミュレーションの構築について記述する。

第 4 章ではシステムにおける不確かさを考慮することで、システム COP の幅を算出し、これを用いた不具合検知の検討を行った。

第 5 章・第 6 章では深層学習の一手法である畳み込みニューラルネットワークを用いて不具合検知・診断の検討を行った。第 5 章ではシステムシミュレーションによる不具合データベースの作成や畳み込みのニューラルネットワークの特徴について記述し、第 6 章では学習・診断結果や考察を示した。

第 7 章では最適制御の検討として、モデル予測制御による低炭素制御に取り組んだ。まず時刻ごとの二酸化炭素排出係数を算出し、これをもとに二酸化炭素排出量が最小となる蓄放熱制御を行った。

第 8 章では本論で検討した不具合検知・診断や最適化の機能を含む次世代 BEMS の構想を提示し、最後に本論の総括を示した。

以上のように、本論の具体的な検討は大きく不具合検知、不具合検知・診断、最適制御の 3 種類に分けられる。本論では事務所 A と工場 B を対象としており、事務所 A は全ての検討を行った。しかし、工場 B は蓄熱槽を有さず、システムとしては事務所 A よりも単純であるため、不具合検知・診断のみの対象とした。

また、近年は Internet of Things (IoT) や Big Data, Artificial Intelligence といった単語に代表されるデータ収集・蓄積・分析に関する技術発展が著しい。BEMS データに様々なアルゴリズムを組み合わせ活用することを目指す本研究はまさにこれらの技術の上に成立するものであり、本研究成果のさらなる発展や普及促進が期待される。

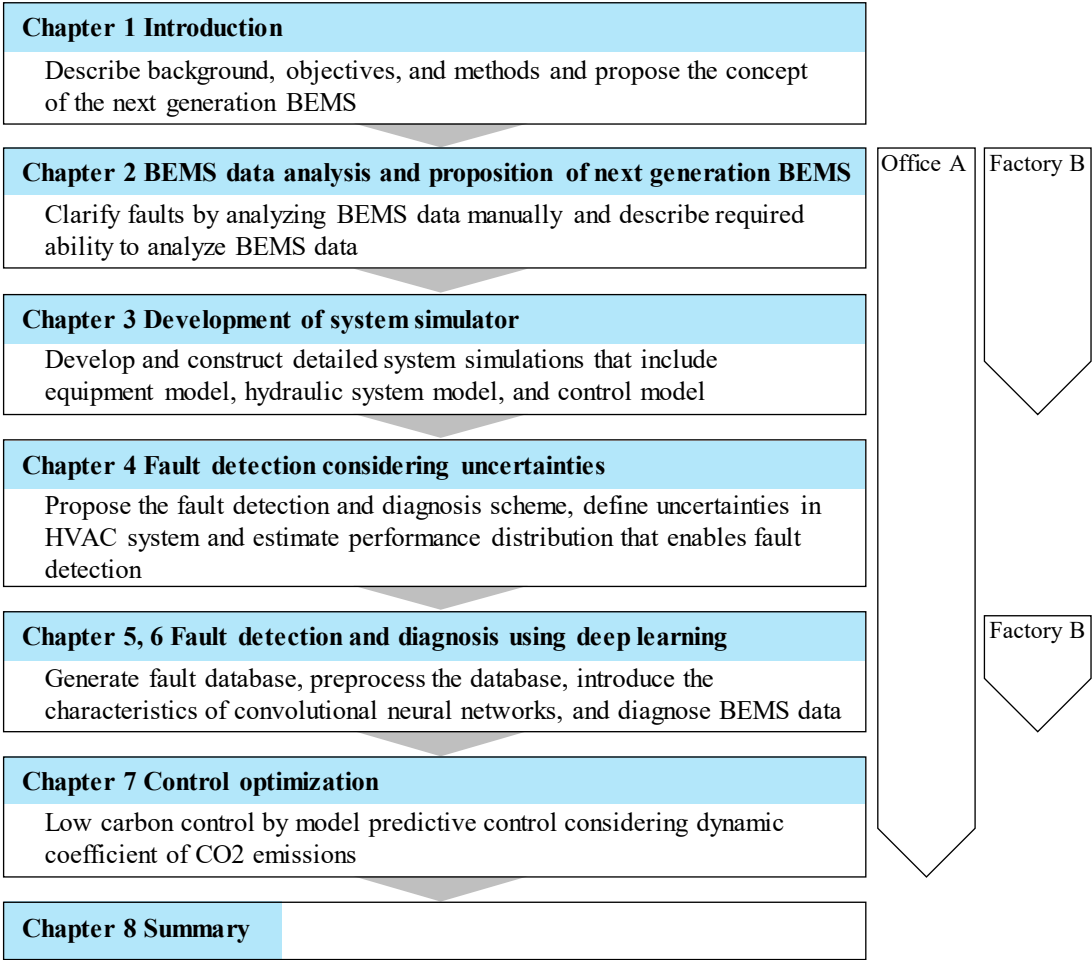


Fig. 1-6 Structure of the dissertation

参考文献

- [1] 環境省 HP :首相官邸 地球温暖化対策推進本部 日本の約束草案, 2015 年 7 月 17 日,
https://www.env.go.jp/earth/ondanka/ghg/mat01_indc.pdf (2019 年 8 月 28 日閲覧)
- [2] 経済産業省 : 長期エネルギー需給見通し, 2015.
- [3] 国立環境研究所 HP : 2015 年度 (平成 27 年度) の温室効果ガス排出量 (確報値) につ
いて, <http://www.nies.go.jp/whatsnew/20170413/20170413.html> (2019 年 10 月 22 日閲覧)
- [4] 温室効果ガスインベントリオフィス HP : 日本の温室効果ガス排出量, http://www-gio.nies.go.jp/aboutghg/data/data-updated_7gas_j.html (2019 年 10 月 22 日閲覧)
- [5] Costa Andrea, Keane Marcus M., Torrens J. Ignacio, Corry Edward : Building operation and
energy performance: Monitoring, analysis and optimisation toolkit, Applied Energy, Vol. 101,
pp.310-316, 2013.
- [6] Pérez-Lombard Luis, Ortiz José, Pout Christine : A review on buildings energy consumption
information, Energy and Buildings, Vol. 40, No. 3, pp.394-398, 2008.
- [7] 経済産業省 資源エネルギー庁 : 平成 30 年度エネルギーに関する年次報告, pp.104,
2019 年 6 月 7 日.
- [8] International Energy Agency : The Future of Cooling Opportunities for energy-efficient air
conditioning, pp.60, 2018.
- [9] Ooka Ryozo, Komamura Kazuhiko : Optimal design method for building energy systems using
genetic algorithms, Building and Environment, Vol. 44, No. 7, pp.1538-1544, 2009.
- [10] Asiedu Y., Besant Robert W., Gu P. : HVAC Duct System Design Using Genetic
Algorithms, HVAC&R Research, Vol. 6, No. 2, pp.149-173, 2000.
- [11] Manuel Mark Christian E., Lin Po Ting, Chang Ming : Optimal duct layout for HVAC using
topology optimization, Science and Technology for the Built Environment, Vol. 24, No. 3,
pp.212-219, 2018.
- [12] Irizarry Javier, Karan Ebrahim P. : Optimizing location of tower cranes on construction sites
through GIS and BIM integration, Journal of information technology in construction (ITcon),
Vol. 17, No. 23, pp.351-366, 2012.
- [13] Shadram Farshid, Mukkavaara Jani : An integrated BIM-based framework for the optimization
of the trade-off between embodied and operational energy, Energy and Buildings, Vol. 158,
pp.1189-1205, 2018.

- [14] Yajima Kazuki, Akashi Yasunori, Lim Jongyeon, Fukui Masahide : Optimization of Design and Construction Process of Heat Source System Utilizing BIM, Proceeding of BS2019 16th International Conference on Building Simulation, 2019. Sep.
- [15] Hyvarinen J., Karki Satu : Building optimization and fault diagnosis source book, IEA Annex25 Final Report Vol 1, 1996.
- [16] Katipamula Srinivas, Brambley Michael R. : Methods for fault detection, diagnostics, and prognostics for building systems—a review, part I, HVAC&R Research, Vol. 11, No. 1, pp.3-25, 2005.
- [17] Fernandez, N., Katipamula, S., Wang, W., Xie, Y., Zhao, M. and Corbin, C.D. : Impacts of Commercial Building Controls on Energy Savings and Peak Load Reduction; Sponsor Org.: USDOE, 2017.
- [18] Roth K. W., Westphalen D., Feng M. Y., Llana P., Quartararo L. : Energy impact of commercial building controls and performance diagnostics: market characterization, energy impact of building faults and energy savings potential, Technical Information Center Oak Ridge Tennessee, 2015.
- [19] Hyvärinen J. : Real Time Simulation of HVAC Systems for Building Optimisation, Fault Detection and Diagnostics, International Energy Agency, Energy Conservation in Buildings & Community Systems Programme., 1999.
- [20] Ahn Byung-Cheon, Mitchell John W., McIntosh Ian BD : Model-based fault detection and diagnosis for cooling towers/Discussion, ASHRAE Transactions, Vol. 107, pp.839, 2001.
- [21] Chen Bin, Braun James E. : Simple rule-based methods for fault detection and diagnostics applied to packaged air conditioners/Discussion, ASHRAE Transactions, Vol. 107, pp.847, 2001.
- [22] Dexter Arthur L., Ngo D. : Fault diagnosis in air-conditioning systems: a multi-step fuzzy model-based approach, HVAC&R Research, Vol. 7, No. 1, pp.83-102, 2001.
- [23] House John M., Vaezi-Nejad Hossein, Whitcomb J. Michael : An expert rule set for fault detection in air-handling units/Discussion, ASHRAE Trans, Vol. 107, pp.858, 2001.
- [24] Wang Shengwei, Cui Jingtian : Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method, Applied Energy, Vol. 82, No. 3, pp.197-213, 2005.

- [25] Schein Jeffrey, Bushby Steven T. : A Hierarchical Rule-Based Fault Detection and Diagnostic Method for HVAC Systems, HVAC&R Research, Vol. 12, No. 1, pp.111-125, 2006.
- [26] Bonvini Marco, Sohn Michael D., Granderson Jessica, Wetter Michael, Piette Mary Ann : Robust on-line fault detection diagnosis for HVAC components based on nonlinear state estimation techniques, Applied Energy, Vol. 124, pp.156-166, 2014.
- [27] Beghi A., Brignoli R., Cecchinato L., Menegazzo G., Rampazzo M., Simmini F. : Data-driven Fault Detection and Diagnosis for HVAC water chillers, Control Engineering Practice, Vol. 53, pp.79-91, 2016.
- [28] Yan Rui, Ma Zhenjun, Zhao Yang, Kokogiannakis Georgios : A decision tree based data-driven diagnostic strategy for air handling units, Energy and Buildings, Vol. 133, pp.37-45, 2016.
- [29] Jessica Granderson : Automated Fault Detection and Diagnostics (AFDD) Performance Testing, Laurence Berkeley National Laboratory, 2018.
- [30] Daniel Veronica : Automated Fault Detection and Diagnostics for the Mechanical Services in Commercial Buildings Project, National Institute of Standards and Technology, 2017.
- [31] Huang W., Lam H. N. : Using genetic algorithms to optimize controller parameters for HVAC systems, Energy and Buildings, Vol. 26, No. 3, pp.277-282, 1997.
- [32] Miyata Shohei, Lim Jongyeon, Akashi Yasunori, Kuwahara Yasuhiro : Optimal set-point regulation in HVAC system for controllability and energy efficiency, Advances in Building Energy Research, pp.1-11, 2019.
- [33] Kintner-Meyer M., Emery A. F. : Optimal control of an HVAC system using cold storage and building thermal capacitance, Energy and Buildings, Vol. 23, No. 1, pp.19-31, 1995.
- [34] 赤司泰義, 渡辺俊行, 龍有, 松尾陽, 高橋淳一 : 複合熱源蓄熱システムの運転計画における最適化効果について, 日本建築学会計画系論文集, 第 62 巻, 第 499 号, pp.27-34, 1997.
- [35] 山口弘雅, 吉田治典 : シミュレーションを用いた水蓄熱式空調システムの最適運転法, 空気調和・衛生工学会 論文集, 第 30 巻, 第 105 号, pp.1-11, 2005.
- [36] Ikeda Shintaro, Ooka Ryo : Metaheuristic optimization methods for a comprehensive operating schedule of battery, thermal energy storage, and heat source in a building energy system, Applied Energy, Vol. 151, pp.192-205, 2015.

- [37] Afram Abdul, Janabi-Sharifi Farrokh : Theory and applications of HVAC control systems – A review of model predictive control (MPC), *Building and Environment*, Vol. 72, pp.343-355, 2014.
- [38] Zhao Yang, Lu Yuehong, Yan Chengchu, Wang Shengwei : MPC-based optimal scheduling of grid-connected low energy buildings with thermal energy storages, *Energy and Buildings*, Vol. 86, pp.415-426, 2015.
- [39] Xiao Fu, Wang Shengwei : Progress and methodologies of lifecycle commissioning of HVAC systems to enhance building sustainability, *Renewable and Sustainable Energy Reviews*, Vol. 13, No. 5, pp.1144-1149, 2009.
- [40] Jean Christophe Visier : Commissioning tools for improved building energy performance, International Energy Agency, Energy Conservation on Building and Community Systems, 2004.
- [41] Parzych R. Bruce, MacPhaul D. : Commissioning the Building Envelope: Surviving Hurricanes Charley, Frances, and Jeanne, National Conference on Building Commissioning, Building Commissioning Association (BCXA) , 2005.
- [42] Noda H., Seki Y., Iino M. : Next-generation BEMS technologies realizing comprehensive energy management of groups of buildings, *Toshiba Review*, Vol. 67, No. 9, pp.8-11, 2012.
- [43] Garcia Carlos E., Prett David M., Morari Manfred : Model predictive control: theory and practice—a survey, *Automatica*, Vol. 25, No. 3, pp.335-348, 1989.
- [44] Granderson Jessica, Lin Guanqing, Blum David, Page Janie, Spears Michael, Piette Mary Ann : Integrating diagnostics and model-based optimization, *Energy and Buildings*, Vol. 182, pp.187-195, 2019.

第2章

BEMS データ分析

2.1. 事務所 A

2.1.1. 建物概要

対象建物は東京都港区に位置する延べ床面積約 16 万平米の大規模事務所ビルである (Table 2-1)。事務所 A は竣工後 10 年以上が経過しているが、継続的な運用改善の取り組みがなされており 2019 年に空気調和・衛生工学会学会賞 (特別賞「十年賞」) を受賞した [1]。

Table 2-1 Overview of Office A

Location	Minato-ku, Tokyo, Japan
Completion	2006, August
Usage	Office, Conference, Restaurant
Site area	18,165 m ²
Total floor area	162,888 m ²
Number of floors	2 (underground), 20, 2(penthouse)

2.1.2. 熱源システム構成

事務所 A の熱源システムの概要図を Fig. 2-1, Fig. 2-2 に示す。特徴としては冷却水の冷却に下水熱を利用していることが挙げられるが、予備機として密閉式冷却塔も設置されている。また、機器仕様表を Table 2-2–Table 2-4 に示す。4 台の冷凍機はすべて性能が異なるため、蓄熱槽を活用する上でエネルギー効率が向上するような制御が行われている。ただし、基本的には夜間蓄熱し、昼間放熱するよう運転される。シミュレーションの構築はこれら機器と制御をすべてモデル化することによって行った。

冬季の温熱供給には熱回収インバータターボ冷凍機である TR1 が利用される。しかし、冬季は冷熱負荷が小さく熱回収モードで運転した場合に冷熱が余剰となるため、実際は温水モードで運転されている。なお、冬季は外気温が低く、もともと下水熱交換機の予備として設置されている冷却塔の利用がみられた。冷却塔利用と下水熱利用の比較や最適制御も課題として取り組むことは可能ではあるが、本研究ではもともとの設計意図通りに下水熱が利用される夏季運転モードを検討対象とした。

本システムは 1 分データがある期間のみ蓄積され、15 分データが竣工以降長期にわたって蓄積されている。そこで以下では 15 分データを用いて分析を行った。

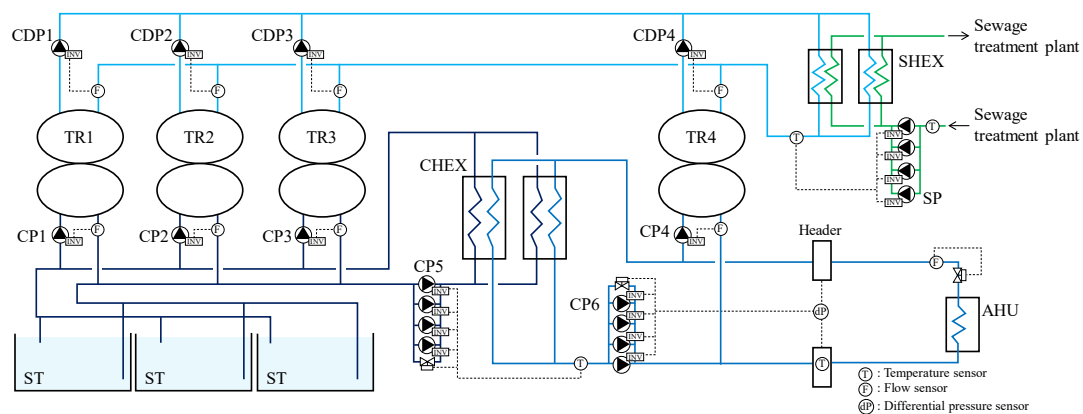


Fig. 2-1 Heat source system in Office A (summer mode)

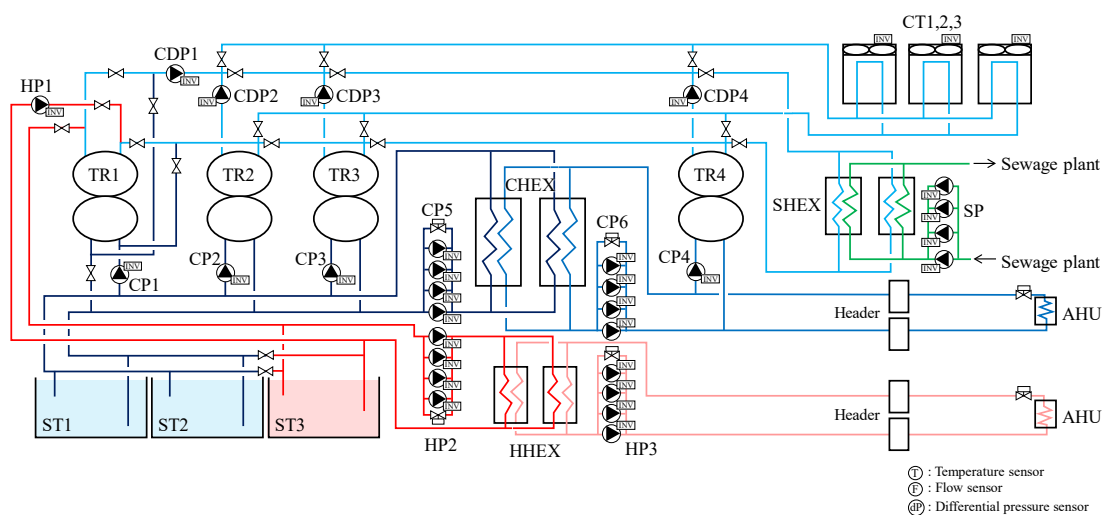


Fig. 2-2 Heat source system in Office A (winter mode)

Table 2-2 Equipment specification for Office A (1)

Name	Equipment	Unit number	Specification		Power [kW]
TR1	Heat recovery inverter turbo refrigerator	1	Cooling capacity	1,723 kW	Cooling mode
			Heating capacity	2,109 kW	278 (Output)
			Chilled water	2.470 m ³ /min	316 (Input)
				15 °C→5 °C	Heat recovery mode
			Hot water	3.070 m ³ /min	353 (Output)
				35 °C→45 °C	
			Condenser water	5.892 m ³ /min	399 (Input)
				32 °C→37 °C	
TR2	Turbo refrigerator	1	Cooling capacity	3,481 kW	530 (Output)
			Chilled water	4.980 m ³ /min	587 (Input)
				15 °C→5 °C	
			Condenser water	11.738 m ³ /min	
				32 °C→37 °C	
TR3	Inverter turbo refrigerator	1	Cooling capacity	3,481 kW	562 (Output)
			Chilled water	4.980 m ³ /min	641 (Input)
				15 °C→5 °C	
			Condenser water	11.830 m ³ /min	
				32 °C→37 °C	
TR4	Turbo refrigerator	1	Cooling capacity	3,481 kW	494 (Output)
			Chilled water	4.980 m ³ /min	547 (Input)
				15 °C→5 °C	
			Condenser water	11.623 m ³ /min	
				32 °C→37 °C	
CT1	Cooling tower	2	Cooling capacity	1,578 kW	5.5×2
			Condenser water	4.522 m ³ /min	
				37 °C→32 °C	
CT2,3	Cooling tower	4	Cooling capacity	3,155 kW	5.5×4
			Condenser water	9.044 m ³ /min	
				37 °C→32 °C	

Table 2-3 Equipment specification for Office A (2)

Name	Equipment	Unit number	Specification		Power [kW]
CP1	TR1 chiller water pump	1	Flow Head	2.470 m ³ /min 18 m	11
CP2	TR2 chiller water pump	1	Flow Head	4.980 m ³ /min 17 m	30
CP3	TR3 chiller water pump	1	Flow Head	4.980 m ³ /min 17 m	30
CP4	TR4 chiller water pump	1	Flow Head	4.980 m ³ /min 35 m	45
CP5	Primary chilled water pump	4	Flow Head	5.340 m ³ /min 32 m	45
CP6	Secondary chilled water pump	4	Flow Head	2.670 m ³ /min 41 m	30
CDP1	TR1 condenser water pump	1	Flow Head	5.892 m ³ /min 32 m	45
CDP2	TR2 condenser water pump	1	Flow Head	11.830 m ³ /min 38 m	110
CDP3	TR3 condenser water pump	1	Flow Head	11.830 m ³ /min 38 m	110
CDP4	TR4 condenser water pump	1	Flow Head	11.623 m ³ /min 38 m	110
SP	Sewage pump	4	Flow Head	8.038 m ³ /min 23 m	55
HP1	TR1 hot water pump	1	Flow Head	3.070 m ³ /min 12 m	11
HP2	Primary hot water pump	4	Flow Head	3.400 m ³ /min 23 m	22
HP3	Secondary hot water pump	4	Flow Head	3.400 m ³ /min 45 m	37

Table 2-4 Equipment specification for Office A (3)

Name	Equipment	Unit number	Specification	
CHEX	Plate heat exchanger for chilled water	2	Capacity	7,454 kW
			Cold side	10.690 m ³ /min 5.5 °C→15.5 °C
			Hot side	10.690 m ³ /min 17 °C→7 °C
HHEX	Plate heat exchanger for hot water	2	Capacity	3,550 kW
			Cold side	5.100 m ³ /min 33 °C→43 °C
			Hot side	5.100 m ³ /min 45 °C→35 °C
SHEX	Plate heat exchanger for sewage	2	Capacity	6,168 kW
			Cold side	16.075 m ³ /min 30.0 °C→35.5 °C
			Hot side	17.682 m ³ /min 37 °C→32 °C
ST1	Water heat storage tank	1	Volume	2,396 m ³
			Temperature	5 °C–15 °C
ST2	Water heat storage tank	1	Volume	2,154 m ³
			Temperature	5 °C–15 °C
ST3	Water heat storage tank	1	Volume	2,154 m ³
			Temperature	5 °C–15 °C 35 °C–45 °C

2.1.3. 夏季代表週の制御状態

2007 年の夏季代表週（8 月 5 日（日）から 8 月 11 日（土））における制御状態を示す（Fig. 2-3, Fig. 2-4）。

二次冷水（供給冷水）に関して、夜間に往温度と還温度がともに低くなっていた（Fig. 2-3 (a)）。夜間に一次冷水流量（放熱用熱交換器（CHEX）の蓄熱槽側）が二次冷水流量（放熱用熱交換器（CHEX）の Air Handling Unit（AHU）側）に対して過大となっていたことが原因であった。夜間蓄熱のために冷凍機が稼働すると冷凍機冷水ポンプ（CP1-CP3）の圧力によって放熱用熱交換器の一次側に流量が生じる。この流量が夜間の二次側の負荷に対して過大であり、本システムには熱交換器横に制御用の二方弁が設定されていないためこのような制御挙動になったと考えられる。この状態は設計の不具合ともみなすことができるが、運用によって直接修正できないため本研究の不具合検知・診断の対象とはしなかった。

Fig. 2-3 (b)では各冷凍機が全て稼働していた。夏季の負荷が大きい時期であるため、夜間蓄熱時に蓄熱系冷凍機である TR1, TR2, TR3 のすべてが稼働し、朝と夕方に直送系冷凍機である TR4 が稼働していた。昼間に冷凍機の稼働がないのは、ピークカット契約を本建物が電力会社と交わしているためである。

二次冷水ポンプ（CP6）は流量に応じて台数が制御されていたが、8 月 10 日の昼間に台数が頻繁に切り替えられていた（Fig. 2-3 (c)）。その前後で消費電力もハンチングしており、Fig. 2-3 (a)からも二次流量が同様にハンチングしていたため、なんらかの要因により流量制御が不安定になり、その結果として台数も同様に不安定な制御になったものと考えられる。流量制御のハンチングの原因として AHU の制御不全が挙げられる。

蓄熱槽は深さ 6m の温度成層型であるため、夜間蓄熱時に底面側から 5°C となり、昼間放熱時に上面側から 17°C となった（Fig. 2-4(a)）。蓄熱系冷凍機の冷水出口温度が 5°C であるため底面側の温度は適切であるが、もともと本蓄熱槽は温度差 10°C で設計されていたため上面側は 15°C になるはずである。放熱用熱交換器（CHEX）の能力が大きめに導入された結果、小さい流量でも熱交換が可能となり CHEX の一次側出口温度が設計時よりも高くなったと考えられる。なお、蓄熱槽における温度差が大きくなることで蓄熱可能な熱量が増加するため、この現象はシステムによって有利に働くものと考えられる。

下水ポンプ（SP）は最大の台数である 4 台で運転されながらも、下水熱交換器（SHEX）の冷却水出口温度はほぼ設定温度に制御されていた（Fig. 2-4(b)(c)）。なお、Fig. 2-4(c)は下水ポンプ稼働時のみの値をプロットした。設定温度が下水入口温度に対して 2°C 以上のアプローチ温度が確保されていたため温度制御が適切になされたと考えられる。ただし、その中でも 8 月 11 日の明け方ではアプローチ温度が他の日より小さく、その結果として下水ポンプの消費電力が増加したものと考えられる。






Fig. 2-3 System behavior in a week in 2007 (Office A, BEMS data) (1)



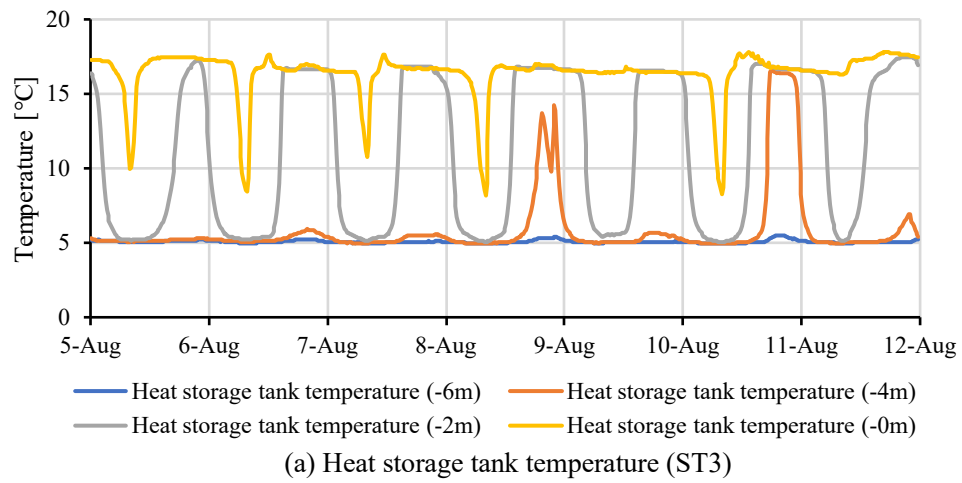


Fig. 2-4 System behavior in a week in 2007 (Office A, BEMS data) (2)

2.1.4. 長期性能

事務所 A は竣工後 10 年以上が経過し、長期的なデータが蓄積されている。そこで、2007 年 1 月から 2016 年 12 月の 10 年間にわたる性能の変動を分析することで、経年的な傾向やばらつきを明らかにした。

Fig. 2-5 に 10 年間の月間 SCOP を示す。月間 SCOP は対象月の供給熱量の積算値を消費電力量で除した値である。2007 年 1 月から 3 月の値が非常に高いが、この期間は二次側のセンサに異常があり供給熱量が大きく測定されていた。事務所 A は運用改善会議が 1~2 ヶ月に 1 回開催されていたため、この不具合に気づくことができ、2007 年 4 月以降は修正がなされた。全体の傾向としては、夏季は SCOP のばらつきが小さく、中間季や冬季においてばらつきが大きかった。夏季は負荷が大きく毎年同じような運転になるのに対し、中間季や冬季では毎年少しずつ冷凍機の運転順位といった運用を変更している可能性があることや、冷却水条件の変化によって冷凍機 COP が変動したことが原因として挙げられる。

SCOP は下水温度や負荷の大きさによって当然変化する。そのため手作業により分析において、SCOP のみからではシステムが適切に運転されているか判断することは難しい。そのため様々な側面から引き続き分析を行った。




Fig. 2-5 Monthly SCOP for 10 years (Office A, BEMS data)

Fig. 2-6 に 10 年間の供給熱量を示す。2007 年 1 月から 3 月は冷熱量の値が他の年と比べて大きいが、先に述べたように供給熱量に関するセンサ異常が原因である。この 10 年間で、2011 年夏季の供給熱量が最も小さかった。事務所 A は震災後に徹底的な節電を行い、照明器具の間引きや照度の抑制による内部負荷低減の効果によるものと考えられる。そのため 2011 年度の温熱供給量はその前後に比べて大きい結果となった。




Fig. 2-6 Monthly supplied heat for 10 years (Office A, BEMS data)

Fig. 2-7 に 10 年間の月間消費電力量を示す。傾向は供給熱量と同様で、2011 年を境に特に夏季の消費電力が減少した。一方、冬季は減少の幅が小さく、近年は 2011 年以前よりも漸増傾向にある。内部負荷低減による暖房負荷の増加が一因として挙げられる。また、全体を通して冷凍機による消費電力量が約 8 割を占めた。そのため、本システムは冷凍機の効率がシステム効率に大きな影響を及ぼすシステムであるといえる。




Fig. 2-7 Monthly power consumption (Office A, BEMS data)

冷凍機以外の消費電力量のうち、冷却塔と下水ポンプの消費電力量を比較した (Fig. 2-8)。設計時は下水ポンプを主に利用し、冷却塔は下水ポンプのメンテナンス時等のバックアップとして導入されていた。しかし、実運用においては冬季に冷却塔がしばしば利用されていた。冬季は外気湿球温度が下水温度よりも低いため、冷凍機の COP 向上のためにこのような制御変更が行われたものと考えられる。




Fig. 2-8 Power consumption of cooling towers and sewage pumps (Office A, BEMS data)

冷水一次ポンプ (CP5) と二次ポンプ (CP6) の消費電力量を比較した (Fig. 2-9)。両者は放熱用熱交換器を挟んで似た運転がなされる。そのため消費電力量の変動も近いものとなった。しかし、冬季の冷熱負荷が小さい期間は一次ポンプと二次ポンプの乖離が大きかった。二次ポンプはヘッド間差圧を一定以上となるように制御されているため、低流量時でも一定以上の消費電力が生じるためだと考えられる。




Fig. 2-9 Power consumption of primary and secondary chilled water pumps
(Office A, BEMS data)

2.1.5. 冷凍機詳細分析

Fig. 2-10 に 10 年間の各冷凍機の月間生産熱量と COP を示す。COP は冷凍機生産熱量を消費電力量で除した値である。TR4 は蓄熱槽に接続しない直送系冷凍機であり、高負荷時に運転されることが設計時から想定されていた。そのため、実運用においても TR4 は夏季のみ運転がなされていた。また、TR1 から TR3 が蓄熱系冷凍機であり熱交換器を介して二次側に熱を供給するため、冷水出口温度が 5°C であるのに対し、TR4 は直接二次側に接続しているため冷水出口温度が 7°C である。そのため、夏季は TR4 の冷凍機の COP が他の冷凍機よりも高い結果となった。

また、TR3 は他の冷凍機と比べて COP のばらつきが大きかった。TR2 や TR4 は定速ターボ冷凍機であるが、TR3 はインバータターボ冷凍機であるため、冷却水温度の変化に応じて COP が大きく変化する。TR1 は冬季において温水モードで運転されるため TR3 ほど高い COP を発揮できなかったと考えられる。




Fig. 2-10 TR monthly heat production and COP for 10 years (Office A, BEMS data)

冷凍機の性能をより詳細に分析するために、冷凍機（TR3）の負荷率と COP の関係を表す性能曲線上に 2007 年の実際の運転点をプロットした（Fig. 2-11）。ここでは、性能曲線（実線）との比較のため、冷水出口温度が 4.95℃ 以上 5.05℃ 以下であり、負荷率が 20%以上の運転点のみをプロットした。

冷凍機は冷水出口温度、負荷率と冷却水出口温度によって COP が変化する。Fig. 2-11 においては各色のプロットを中心に実線である性能曲線が位置すれば実運転において設計通りの性能が発揮されていると判断できる。冷却水出口温度が 21℃ 以下の場合では設計通りの COP が発揮されていたが、17℃ や 13℃ 付近のプロットを見ると性能曲線よりも下側に分布している。そのため、冷却水出口温度が低い場合は想定通りの性能を発揮できていないことがわかる。




Fig. 2-11 TR3 performance plot in 2007 (Office A, BEMS data)

なお、冷凍機の負荷率と COP の関係について、その許容誤差が JIS にて Eq. (2-1)の範囲内と定められている[2]。

$$Tol = 10.5 - (0.07 \times pl) + \frac{833}{\Delta T_{fl} \times pl} \quad \text{Eq. (2-1)}$$

Where Tol is the tolerance [%], pl is the partial load [%], and ΔT_{fl} is the inlet and outlet chilled water temperature difference at the full load.

これをグラフ化すると Fig. 2-12 のようになり、負荷率が小さいほど性能曲線と計測値の間の許容誤差が大きくなることがわかる。そのため、負荷率が小さい場合に性能曲線通りの COP が発揮できなくなる Fig. 2-11 の分析結果は JIS に則った傾向を実際の機器が有していることを示していると考えられる。




Fig. 2-12 Tolerance of COP based on partial load ($\Delta T_{fl} = 10$)

引き続き TR3 について、経年的な性能評価を試みた。冷凍機の COP は冷水出口温度、負荷率と冷却水温度によって決まるため、これらの値に対して本来あるべき COP を性能曲線から算出し、その値と実際の COP との比を算出した (Fig. 2-13)。なお、性能曲線との比較のために、冷水出口温度が 4.95°C 以上 5.05°C 以下、冷水出口温度は 18°C 以上 37°C 以下、負荷率は 20%以上をプロットの条件とした。

TR3 は冬季に冷水出口温度が 7°C で運転されていたため、基本的に夏季のプロットとなった。2011 年や 2014 年のプロットは前年 (2010 年, 2013 年) よりも高かった。TR3 は 2011 年 2 月 7 日から 15 日, 2014 年 6 月 12 日から 14 日の期間にチューブ洗浄を行っており、その結果として性能が回復したものと考えられる。チューブ洗浄の直前と直後の月間平均 COP 比は 2011 年 2 月の前後が 91.7% (2010 年 11 月), 100.6% (2011 年 5 月) であり, 2014 年 6 月の前後が 91.9% (2013 年 10 月), 102.9% (2014 年 7 月) であった。そのため、チューブ洗浄によって性能が仕様書通りに回復し、その回復率は約 10%であった。ただし、冷凍機の特長として負荷率が小さい場合に性能曲線通りの性能が発揮されにくいことを考慮すると、チューブ汚れによる性能低下の影響は 10%よりも小さい可能性がある。






Fig. 2-13 TR3 COP ratio for 10 years (Office A, BEMS data)

2.1.6. 下水ポンプ詳細分析

下水ポンプ (SP) が適切に制御されているか分析するために、まず下水熱交換器 (SHEX) において処理された熱量と下水ポンプ消費電力の関係をプロットした (Fig. 2-14)。熱交換器の出入口温度差が一定であれば、処理熱量と流量は比例関係となり、ポンプ消費電力は処理熱量の 3 乗に比例するはずである。2008 年 8 月のプロットはそのような傾向がみられるが、2013 年 8 月のプロットは全く異なっていた。消費電力が約 160kW に集中し、ポンプが処理熱量に関わらず最大限稼働していた。



(a) August 2008



(b) August 2013

Fig. 2-14 Sewage pumps performance (Office A, BEMS data)

下水ポンプの適切な制御について把握するために、下水熱交換まわりの設計条件を示す (Fig. 2-15)。左側が冷凍機冷却水側、右側が下水側である。下水熱交換器の定格流量は下水側が $32.15 \text{ m}^3/\text{min}$ 、冷却水側が $35.364 \text{ m}^3/\text{min}$ である。その一方で各冷凍機の冷却水ポンプの定格流量の和が $29.46 \text{ m}^3/\text{min}$ 、下水ポンプの定格流量の和が $32.152 \text{ m}^3/\text{min}$ であるため、下水ポンプはたとえ冷却水ポンプがすべて定格で運転したとしても、全台が定格で稼働することは本来ないはずである。また、温度の関係をみると、下水温度が 30°C の時に冷却水の出口温度が 32°C であるため、両者の差であるアプローチ温度 2°C を前提とした制御は適切になされるはずである。




Fig. 2-15 Designed conditions related to SHEX

しかし、時系列データで分析すると 2008 年は冷却水出口温度設定値が頻繁に変更されて下水ポンプも無理なく制御されていたのに対し、2013 年は冷却水出口温度設定値が一定であった (Fig. 2-16)。その結果、下水温度とのアプローチ温度が小さいため下水ポンプが過剰に運転されてしまったと考えられる。

本システムは冷却水出口温度設定値を手動でのみ設定可能であることが本質的な課題である。本来であれば下水温度に基づいた設定値を逐次算出・設定することが望ましいが、手動では頻繁な設定値変更は難しい。そのため設定値が逐次更新されるようにシステムを改善することが期待される。





Fig. 2-16 Sewage pumps control in a week (Office A, BEMS data)

2.1.7. 熱交換器詳細分析

本システムに導入されているプレート式熱交換器は冷凍機のチューブと同様、汚れによって熱交換効率が低下する。冷水放熱用熱交換器 (CHEX) の機器仕様は Fig. 2-17 のようになり、同じ流量で熱交換効率が低下した場合は二次冷水出口温度が上昇してしまう。実際には一次側の流量が二次側出口温度を参照しながら制御されるため、熱交換効率が低下すると一次側の流量が増加し、同時に一次側出口温度の低下や一次ポンプの消費電力の増加が生じると考えられる。

熱交換器の効率低下によるシステム挙動の変化は、複数の項目へ影響が生じるため時系列グラフ化による評価が難しい。そこで、第3章 2.3.節における熱交換器モデルを用いて熱交換器のパラメータを BEMS データから同定し、その分析を行った。ここでは、熱交換効率を表すパラメータとして、熱交換面積を用いた。なお、熱交換面積が大きいほど熱交換効率も高いことを意味する。




Fig. 2-17 CHEX designed conditions

Fig. 2-18 に 2007 年と 2015 年の 8 月における熱交換面積の推定結果を示す。なお、図には一日の推定値の平均を示した。結果として 2015 年の方が 2007 年に対して推定熱交換面積が減少し、減少率は平均約 26%であった。この不具合は流量や温度といった計測データのみを用いるだけでは診断が難しく、性能に関するパラメータを機器モデルにより推定することで可能となった。




Fig. 2-18 CHEX estimated heat exchange area (Office A, BEMS data)

2.2. 工場 B

2.2.1. 建物概要

工場 B は宮城県仙台市に所在する半導体用の工場である。用途は工場に加え、食堂も有する (Table 2-5)。2011 年の東日本大震災の時に被災したが、その後改修を経て運用が再開された建物である。

Table 2-5 Overview of Factory B

Location	Sendai, Miyagi, Japan
Completion	2006 (renovated in 2011)
Usage	Factory, Restaurant
Site area	95,539 m ²
Total floor area	27,705 m ²

2.2.2. 熱源システム構成

Fig. 2-19 に工場 B の熱源システムを示す。冷凍機、冷却塔、各冷凍機の冷水・冷却水ポンプ、二次冷水ポンプで構成される非常にシンプルなシステムである (Table 2-6)。冷凍機台数制御, 一次冷水ポンプ変流量制御, 二次冷水ポンプ台数制御, 二次冷水ポンプ変流量制御, 冷却水ポンプ変流量制御, 冷却水バイパス弁制御, 冷却塔変風量制御が行われている。冷却塔は冷凍機に並列に接続されており, 冷凍機の運転台数にかかわらず常時 2 台運転される。

ヘッダ間のバイパスには常に冷水が流れており, 二次側の流量に対して冷凍機冷水流量の合計が 1.1 倍となるよう各ポンプが制御されている。これによって, 二次側へ安定した冷水を供給するという特徴がある。

この工場 B は年間を通じて冷熱需要があり, かつ 24 時間体制で稼働するため冷熱負荷も 24 時間生じる。ただし, ゴールデンウィークやお盆といった休業期間中はシステムを停止してメンテナンスを行う場合がある。

本システムは 2013 年と 2014 年の 2 年間のみ 15 分データを入手することができた。そこで以降ではこれらのデータを用いた分析を示す。

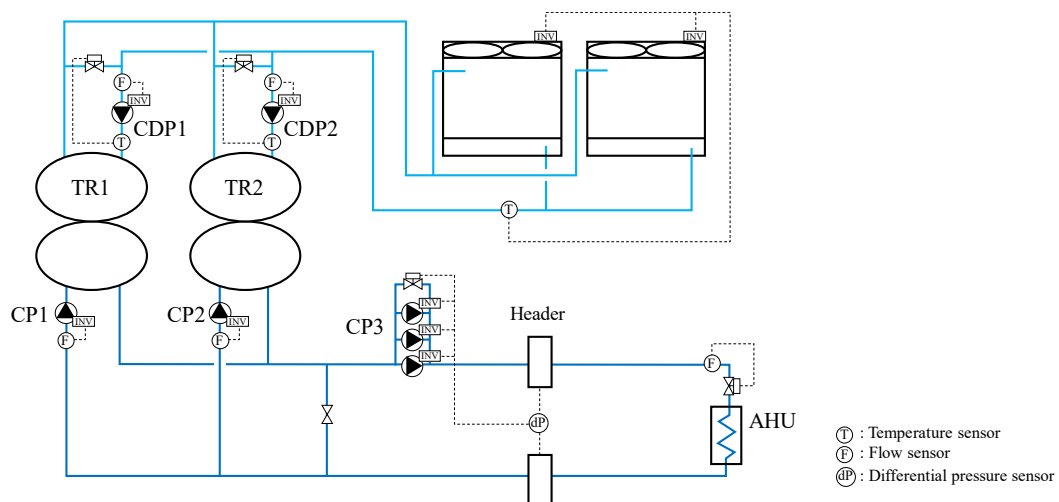


Fig. 2-19 Heat source system in Factory B

Table 2-6 Equipment specification for Factory B

Name	Equipment	Unit number	Specification		Power [kW]
TR1,2	Turbo refrigerator	2	Cooling capacity	1,758 kW	298 (Input) 266 (Output)
			Chilled water	3.145 m ³ /min	
				15 °C→5 °C	
			Condenser water	5.925 m ³ /min	
				32 °C→37 °C	
CP1,2	TR Chilled water pump	2	Flow	3.145 m ³ /min	18.5
			Head	200 kPa	
CP3	Secondary chilled water pump	3	Flow	3.145 m ³ /min	37
			Head	400 kPa	
CDP1,2	TR Condenser water pump	2	Flow	5.925 m ³ /min	45
			Head	250 kPa	
CT1,2	Cooling Tower	2	Flow	5.925 m ³ /min	7.5×2
			Wet bulb temp.	27 °C	

2.2.3. 夏季代表週の制御状態

2013 年の夏季代表週（8 月 4 日（日）から 8 月 10 日（土））の制御状態を Fig. 2-20, Fig. 2-21 に示す。


二次冷水流量に関して、1 日の中での昼間と夜間の差が小さかった（Fig. 2-20(a)）。例えば、ピーク時（8 月 7 日 10:45）に $3.23 \text{ m}^3/\text{min}$ であるのに対し、夜間は $2.33 \text{ m}^3/\text{min}$ であった。これは、対象建物が工場であり、夜間も高い熱負荷が生じているためだと考えられる。また、冷水往還温度差は 8°C から 9°C が確保されていた。設計時の想定が往き温度 7°C 、還り温度 15°C であったため、二次側は適切に制御されていると考えられる。

夏季代表週では冷凍機は常に 2 台稼働し、その消費電力はほぼ同じであった（Fig. 2-20(b)）。わずかに TR2 の方が TR1 よりも消費電力が大きかった。本システムは負荷を直接冷凍機が処理するため、事務所 A のように COP が高くなる負荷率で運転することができない。そのため消費電力も負荷に応じて上下している。


二次冷水ポンプも冷凍機と同様負荷に応じて消費電力が上下した（Fig. 2-20(c)）。8 月 4 日のみ二次冷水流量が小さく 1 台で運転がなされていた。

TR1 の冷却水ポンプは、常に一定の流量と消費電力であった（Fig. 2-21 (a)）。その一方で、冷却水流量設定値として記録されていたデータは負荷に応じた値であった。そのため、冷却水流量が設定値通りに制御されていない可能性がある。


冷却塔のファン消費電力と冷却塔によって冷却された熱量によると、事務所 A の下水ポンプのようにファンが最大限稼働したままになってしまうといった不具合は生じていないことがわかる（Fig. 2-21(b)）。また、冷却塔の冷却水出口温度も設定値通りに制御されており、冷却塔は適切に制御されていると判断できる。なお、本システムにおける冷却水出口温度の設定値は外気湿球温度に応じて逐次設定値が決定される。そのため事務所 A の下水ポンプのような不具合が生じてないと考えられる。



(a) Supplied chilled water flow and temperature




(b) TRs power




(c) Secondary pumps power and operating number


Fig. 2-20 System behavior in a week in 2013 (Factory B, BEMS data) (1)



(a) TR1 condenser water pump



(b) Cooling towers power and cooled heat



(c) Cooling towers temperature control

Fig. 2-21 System behavior in a week in 2013 (Factory B, BEMS data) (2)

2.2.4. 長期性能

本節ではデータが入手可能であった 2013 年と 2014 年の 2 年間の比較を中心に月単位の長期性能を分析した。

工場 A は冷却水の冷却に冷却塔を利用しているため、外気湿球温度が低い冬季は夏季に対して月間 SCOP が上昇した (Fig. 2-22)。しかし、1 月と 2 月に関して、2014 年は 2013 年に対して SCOP・COP が低下した。冷凍機の冷水出口温度が 2013 年の 9°C から 2014 年は 7°C へ変更されていたため、2014 年の方が SCOP は低くなったと考えられる。冷水の供給温度が高い場合、要求負荷の状況と AHU の能力によっては制御に悪影響を及ぼす可能性があることには留意が必要である。




Fig. 2-22 Monthly SCOP for 2 years (Factory B, BEMS data)

供給熱量と平均外気温度を Fig. 2-23 に示す。2013 年に比べて 2014 年は供給熱量が小さい傾向であった。特に 5,6,7 月において、2014 年の方が平均気温は高いにもかかわらず供給熱量が小さかった。このことから、工場の稼働状況は 2013 年の方が活発だった可能性が考えられる。




Fig. 2-23 Monthly supplied heat and outdoor air temperature (Factory B, BEMS data)

冷凍機とその他の機器の消費電力量を Fig. 2-24 に示す。1 月と 2 月は 2013 年に対して 2014 年では冷凍機消費電力量が低下したにもかかわらず、その他の消費電力量は増加した。2014 年は 2013 年よりも供給熱量も小さく、冷凍機とその他ともに消費電力量は減少するべきである。そのため、冷凍機以外の機器において何らかの不具合が生じた可能性が想定される。




Fig. 2-24 Monthly power consumption for 2 years (Factory B, BEMS data)

そこで、Fig. 2-25 に各ポンプと冷却塔の消費電力量を示す。2013 年 7 月以降冷却水ポンプの消費電力量はそれまでに対して大きな値を維持していた。そのため、冷却水ポンプの制御に何らかの不具合が生じたと推測される。この不具合に関する詳細な分析は 2.2.6.にて行った。




Fig. 2-25 Power consumption in pumps and cooling towers (Factory B, BEMS data)

2.2.5. 冷凍機詳細分析

Fig. 2-26 に2年間における各冷凍機の生産熱量と COP を示す。2013 年では TR1 が多く稼働していたが、2014 年では TR2 の方が多く稼働していたため、現場にて何からの制御変更がなされたと考えられる。2014 年 1 月に TR1 の COP が TR2 よりも低かったため、TR2 を優先的に稼働するようにしたものと考えられる。

本システムは冬季の冷凍機 COP が 15 を超える場合があるため、冷却水温度が低い場合の部分負荷効率が非常に高い冷凍機を活用できていることがわかる。

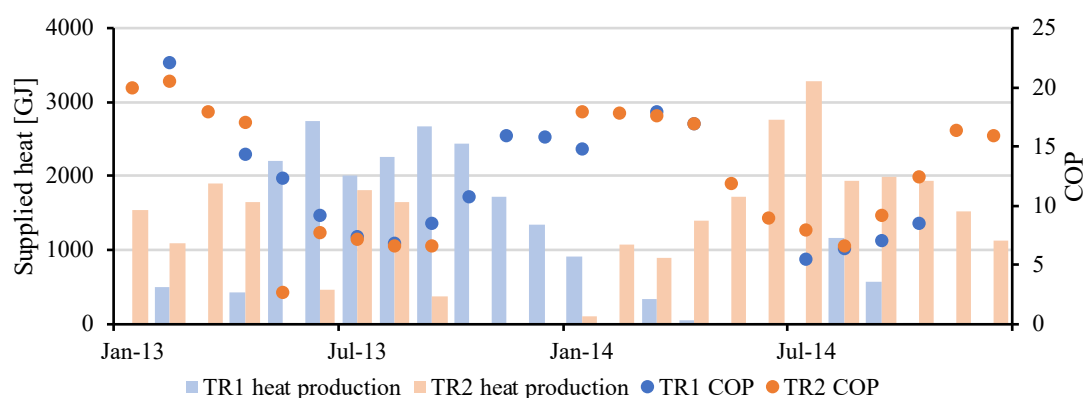


Fig. 2-26 TR heat production and COP in 2013 (Factory B, BEMS data)

2013 年に多く稼働していた TR1 に関して、負荷率・COP・冷却水出口温度の関係を Fig. 2-27 にプロットした。なお、性能曲線と適切に比較するために、冷水出口温度が 6.95°C 以上 7.05°C 以下、負荷率 10%以上の運転点のみを利用した。事務所 A の冷凍機のプロット (Fig. 2-11) と同じく、冷却水出口温度が 21°C 以上と比較的高い場合は性能曲線とほぼ同じ性能を発揮できているが、冷却水出口温度が低くなるほど想定通りの性能は発揮されていなかった。しかしながら COP が 20 を超える運転点があるため、非常に高いエネルギー効率を有する冷凍機だといえる。

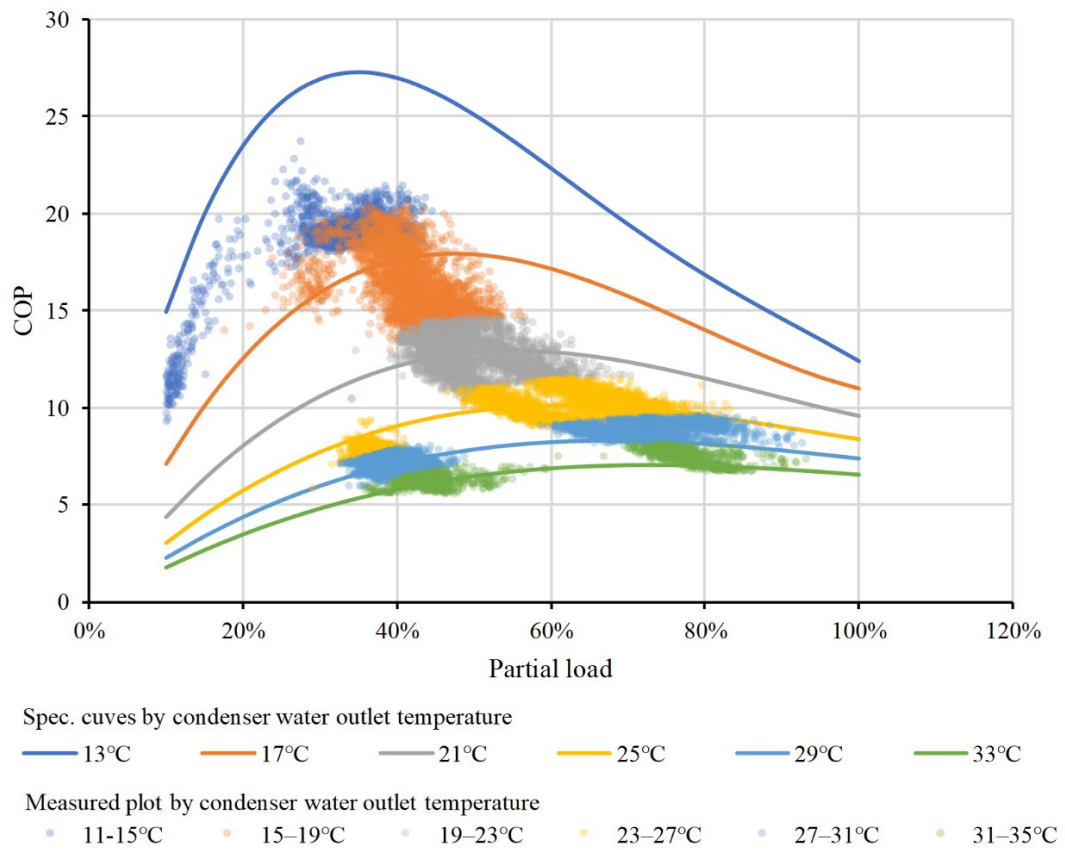


Fig. 2-27 TR1 performance plot in 2013 (Factory B, BEMS data)

2.2.6. ポンプ詳細分析

長期性能分析において、冷却水ポンプの消費電力量が大きくなっていることがわかった。そこでまず冷却水流量の設定値が適切に与えられているかを分析した。

本システムにおける冷却水流量は、冷凍機負荷率・外気湿球温度に基づき設定値が決定される (Fig. 2-28)。そこで、負荷率 20%以上の運転点に関して冷凍機負荷率と冷却水ポンプ設定値の散布図を作成した (Fig. 2-29)。




Fig. 2-28 Condenser water flow setting based on TR partial load and wet bulb temp.

その結果、分布の形状は Fig. 2-28 に従うものであるため、設定値はロジック通りに決定されていることが確認された。そのため、Fig. 2-21(a)も考慮すると冷却水ポンプが設定値を満たすよう制御されていないことがわかった。

設定値と冷却水流量が乖離していた代表週として、2013 年 12 月の一週間の制御状態を示す (Fig. 2-30)。この期間も冷却水流量は設定値まで下げられず、ポンプインバータ周波数が下限値で一定となっていた。そのため、この不具合は冷却水ポンプインバータ周波数の下限値が大きく設定されたことが原因で生じたと考えられる。これをインバータ下限値設定不全とした。




Fig. 2-29 Relationship between TR1 partial load and condenser water flow setting (2013)
(Factory B, BEMS data)




Fig. 2-30 TR1 condenser water pump control in a week in 2013 (Factory B, BEMS data)

二次冷水ポンプ（CP3）は3台あり、二次冷水流量に従って台数制御がなされている。台数制御は増段時と減段時に異なる閾値が与えられ、ハンチングが起きにくいように工夫がなされている（第3章4.2節参照）。

そこで、二次冷水流量と二次冷水ポンプ運転台数の散布図から台数制御が適切になされているか確認した（Fig. 2-31）。基本的に適切に台数は制御されていたが、200 m³/h を超えているにもかかわらず1台で運転されている運転点があった。

流量が大きいにもかかわらず1台で運転されていたのは、ゴールデンウィークの期間中であつた（Fig. 2-32）。特に、5月3日から5月6日まで通常時とは異なる挙動しており、データが全て0となっている時間帯もあつた。そのため、この期間のデータはシステムの通常運転時の制御の評価に適していない。以上を踏まえると、二次冷水の台数制御は適切に行われていたと判断できる。




Fig. 2-31 Secondary pumps operating number control in 2013 (Factory B, BEMS data)




Fig. 2-32 Secondary pumps control in Golden Week in 2013 (Factory B, BEMS data)

2.3. データ分析によって診断された不具合

上述のように、手作業によるデータ分析の結果、複数の不具合が明らかになった。

事務所 A では二次冷水の計測値異常、冷凍機の経年的な効率低下、下水ポンプの制御設定値不全、熱交換器の効率低下がみられた。事務所 A に関しては継続的な運用改善により計測値の異常は修正され、冷凍機の性能低下はチューブ洗浄によって改善されていた。

工場 B では冷却水ポンプのインバータ周波数下限値が不適切であった。2013 年の 7 月に変更された下限値が冬季も放置されたことで、冷却水流量が過剰になってしまったと考えられる。

このような BEMS データの分析を通し、熱源システムにおける不具合には機器単体の性能低下に加え、制御不全も実際に生じていることが示された。手作業による BEMS データ分析において、機器単体の性能低下を診断するためには機器特性を理解し、BEMS データから性能を把握するために数値計算を行うことが求められ、制御不全を診断するためには制御ロジックの理解と、システムがそのロジック通りに制御された場合の流量や温度といった各項目の挙動を想定することが求められることを示した。そのため BEMS データ分析によって熱源システムの不具合を検知・診断するためには幅広い知識とデータ分析の素養が必要であるため、非常にハードルが高い。本研究の最終的な目的のひとつは、これらをシミュレーションと深層学習等により自動化することである。

また、データ分析の前段階として、生データの数値と項目名の一致の確認、理解や分析対象とするデータ項目の抽出、月ごとのファイルの年間のファイルへの変換や、欠損値・異常値への対応にも多くの労力が割かれた。このような生データの処理を効率化するデータクレンジングは、本研究では検討の対象外である。しかし、データのスムーズな活用には不可欠な技術であるため今後の課題である[3]。

2.4. 小括

本章では、本研究で対象とする 2 つのシステムの BEMS データを詳細に分析し、各システムの性能を評価し、生じている不具合を明らかにした。また、従来の BEMS 構成の問題点を指摘し、次世代 BEMS の構成を提案した。得られた主な知見を以下に示す。

①事務所 A の不具合

10 年間にわたる BEMS データを分析した結果、事務所 A では冷凍機や熱交換器の経年的な性能低下や下水ポンプ制御設定値不全が生じていることが明らかとなった。

②工場 B の不具合

入手可能であった 2 年間の BEMS データを分析した結果、冷却水ポンプのインバータ周波数下限値の設定が不適切であることが明らかとなった。

事務所 A、工場 B とともにこれらの結果を得るためには、BEMS を導入するだけでは難しく、BEMS データ分析の過程で機器特性や物理式に基づいた性能指標の算出や制御ロジックに基づいた適切な制御状態の想定が必要であることを示した。

データ分析によって実際に運転されている熱源システムにおける様々な不具合の実態が明らかとなったが、これらの不具合が取り除かれた場合に SCOP がどの程度向上するかを BEMS データ分析のみから明らかにすることは難しい。不具合によって制御状態が変化しており、不具合が取り除かれた場合の制御状態を得るにはシミュレーションが不可欠なためである。そのため、SCOP の性能向上については第 4 章において参考として示した (4.4.3 参照)。

参考文献

- [1] 井上 哲：ソニーシティにおける"エミッション ZEB"を目指す CO₂削減の取り組み (第 57 回空気調和・衛生工学会賞,特別賞第 19 回十年賞・第 7 回リニューアル賞,振興賞第 33 回技術振興賞・第 16 回住宅環境設備賞,第 28 回篠原記念賞,第 9 回井上宇市記念賞および第 16 回功績賞)--(第 19 回空気調和・衛生工学会特別賞"十年賞"受賞業績), 空気調和・衛生工学, 第 93 巻, 第 7 号, pp.581-584, 2019.
- [2] JIS : B8621 遠心冷凍機, 2019.
- [3] Mathew Paul A., Dunn Laurel N., Sohn Michael D., Mercado Andrea, Custudio Claudine, Walter Travis : Big-data for building energy performance: Lessons from assembling a very large national database of building energy use, Applied Energy, Vol. 140, pp.85-93, 2015.

第3章

熱源システムシミュレーション プログラム構築

3.1. 本章の背景と目的

3.1.1. 本研究で志向するシミュレーションプログラム

空調システムの様々な研究においてシミュレーション (simulation) プログラムは用いられているが、同様の概念にエミュレーション (emulation) という言葉がある。これらの動詞形であるシミュレート (simulate) とエミュレート (emulate) の意味を Oxford Advanced Learner's Dictionary 9th edition で引くと、以下のように書かれている。

simulate

2. ~sth to create particular conditions that exist in real life using computers, models, etc, usually for study or training purposes

emulate

2. ~sth (computing) (of a computer program, etc.) to work in the same way as another computer, etc. and perform the same tasks

両者の意味はほぼ同じであるが、simulate はコンピュータを用いてある特定の状態を作り出すこと、emulate は他のコンピュータと同じ動作をさせること、という意味で emulate の方が意味の範囲が狭い。なお、空調システムの分野でも emulator という言葉はしばしば用いられる[1][2]。空調システムという物理システムのモデルを emulator と呼んでいる時点で辞書本来の意味とは異なり、より詳細なモデルまたはリアルタイムでの活用といった文脈で用いられる場合があるなど、両者の明確な使い分けはなされていないのが現状である。そのため、本研究ではより一般的な言葉である simulation を用いることとする。

シミュレーションプログラムは、コンピュータプログラムにおけるコード一文一文の積み重ねで構成される。そのため、労力の観点や結果の妥当性のために無駄なコードは一文とも必要ない。この意味で、シミュレーションプログラムは目的に直接対応して作成されるべきである。なお、近年 Cyber Physical System (CPS) と呼ばれる、コンピュータ上に現実世界を再現するという概念が提唱されているが[3]、これは無目的に構築されるものではなく、各目的に対応したプログラムの集積であると私は考えている。

以上より、本研究の目的が不具合検知・診断と最適化であることを考慮すると、本研究で用いるシミュレーションプログラムは以下の要件を満たす必要がある。

(1) 不具合検知・診断にプログラムを活用するための要件

- ・理論式や機器仕様書、制御仕様書をもとに構築され、負荷等を入力値としたシステム本来の性能が算出可能であること
- ・不確かさによる影響を組み込むことで、システムが発揮しうる性能分布が算出可能であること
- ・不具合の要因となる事象を組み込むことで、不具合によるシステム挙動が算出可能であること

(2) 最適制御にプログラムを活用するための要件

- ・ 設定値の変更によるシステム挙動の変化を原理的に算出可能であること
- ・ 制御手法そのものを柔軟に変更することでシステムの性能を最大限引き出すことが可能であること

以上を計算可能とするために機器モデル, 水搬送系モデル, 制御モデルの 3 種類の観点からモデル化・プログラムの作成を行った。

3.1.2. 既往の空調システムシミュレーションプログラム

システムのモデル化は、一般的にその手法によって white-box model, grey-box model, black-box model に分けられる。White-box model は first principles model と呼ばれるが、徹底的に原理的なモデルを指す。White-box model は対象システムにおけるあらゆる事象が説明可能となるため非常に有用であるが、モデル化の難易度が非常に高いため、通常は原理的なモデルと簡略化したモデルが併用される。これが grey-box model と呼ばれる。Black-box model は機械学習に代表される、機器やシステムの原理を考慮せずにデータのみから作成されたモデルである。データさえあれば容易に作成が可能であるが、データの範囲外の事象を説明できないため、black-box model の適用範囲は限定的である。

これまで様々な空調システムのシミュレーションプログラムが開発されてきたが、多くはできる限り原理的にモデル化を行うことが志向されたプログラムである。冷凍機の内部までを完全に原理的にモデル化したものはさすがにみられないが、それ以外の面では最大限 white に近い grey-box model である。

海外の代表的なプログラムとしては HVACSim+や EnergyPlus, TRNSYS などが挙げられる。HVACSim+は空調システムの動的計算を行うために米国 National Bureau of Standards (現 NIST, National Institute of Standards and Technology) によって 1980 年代に開発されたプログラムで、空調システムのシミュレーションとしては最も古いもののひとつである[4]。HVACSim+は流量の算出に流量バランス計算を採用している点が特徴である。

EnergyPlus は 1996 年に US federal agency によって、当時存在していた 2 つのプログラム (DOE-2, BLAST) をもとに開発が開始されたエネルギーシミュレーションプログラムである[5]。冷却塔などの機器モデルは原理的にモデル化がなされている一方で、利用できる制御が限定的である。

TRNSYS は 1975 年から商用化がなされた、空調システムと熱負荷を同時に解くことができるプログラムで、特に太陽熱利用のコンポーネントが発達している[6]。

また、米国 Laurence Berkeley National Laboratory (LBNL) を中心に Modelica Buildings Library[7]が開発されている。制御モデルも詳細に組み込めるような形になっているが、現在はまだ開発段階にあり、様々なコンポーネントが充実しようとしている段階である。

国内の代表的なプログラムとしては BEST や LECM ツールが挙げられる。BEST (Building Energy Simulation Tool) [8]は 2005 年に国土交通省住宅局の支援により開発が着手され現在もなお開発が進められているプログラムである。動的熱負荷計算プログラム HASP/ACLD と空調システムシミュレーションプログラム HASP/ACSS を基に開発がなされたもので、PID 制御も組み込まれており制御の設定もある程度可能であるが、元から組み込まれている制御しか利用できず、流量バランス計算を用いて流量を解いていないため、制御状態やポンプ動力を本質的に計算できないという問題点がある。

LECM (Life Cycle Energy Management) ツールは表計算ソフト上で動作し、空調システムの年間エネルギー消費量を簡易にシミュレーションするプログラムである[9]。これらのプ

プログラムは設計段階の機器容量の算定や制御手法の検討といった、システム設計検討や運用段階のシステム性能評価などに活用されることが目的であるが、実際には設計段階の利用にとどまる。実システムは制御が非常に複雑であり、これらを汎用的なプログラムですべて再現することは非常に困難であるため、既存のプログラムではエネルギー消費量の概算にとどまってしまうと考えられる。

また、建築物のエネルギー消費性能の向上に関する法律（建築物省エネ法）、エネルギーの使用の合理化等に関する法律（省エネ法）に関連する平成 28 年省エネルギー基準に準拠したエネルギー消費性能の評価を行うことを目的として、エネルギー消費性能計算プログラムが公開されている[10]。本プログラムはエネルギー消費性能の評価には有用であるが、先進的な最適制御等の検討には適していない。

3.1.3. 本章の目的と手法

既往プログラムを利用する利点は, BESTEST[11]のような形で他プログラムとの比較がなされ, プログラムの計算結果が部分的であっても検証されている点である。熱負荷計算は既往プログラムでの多くの比較検証がなされている一方で, 熱源システムシミュレーションは状況が異なる。

熱源システムの挙動は, 負荷や外気温湿度といった入力 (境界条件) に対し, 各機器の特性と各制御の積み重ねによって決定される。そのため, 既往プログラムを利用せずとも, 一つ一つを適切にモデル化して接続すればシミュレーションの構築が可能である。

そこで, 本章では 3.1.1 節で述べたシステム本来の挙動, 不確かさの導入, 不具合挙動の算出, 最適制御への適用といった各目的に応じた柔軟なアレンジが可能な熱源システムシミュレーションの構築を目的とする。本研究では熱源システムシミュレーションを独自にコーディング・構築することとした。なお, コーディングには MATLAB の m 言語を用いたが, python や Fortran といった言語でも同様に作成することは可能である。

なお, 空調システムシミュレーションの構築にあたって, 動的 (dynamic) モデルか静的 (static) モデルかという観点がある。動的モデルは以下のように説明される[12]。

We consider as “dynamic” a model where at least one output variable is dependent on the values of input variables at a time earlier than the time considered




Fig. 3-1 Static/Dynamic model, cited from [12]

この意味では本研究では構築するシミュレーションプログラムは動的モデルである。なぜならば、蓄熱槽や PI 制御が組み込まれているため、前時刻以前の挙動が現在時刻の挙動に影響を及ぼすからである。ただし、ポンプや冷凍機など、前時刻の値を用いない機器モデルもあるため全ての要素モデルが動的ではない。そのため、制御の過渡状態を表現可能という意味で準動的（quasi-dynamic）モデルとみなすのが適切だと思われる。

冷凍機やポンプを動的にモデル化することで、起動時の挙動をより正しく表現可能になると考えられる。しかし、本研究では起動特性まで考慮した検討を行わないこと、利用した BEMS データが基本的に 15 分間隔であったことを踏まえ、冷凍機やポンプは性能曲線に基づく静的なモデルとした。

3.2. 機器モデル

3.2.1. 冷凍機

冷凍機は熱源システムにおいて熱を生産する最も重要な機器であり、消費電力が占める割合も最も大きい。そのため適切なモデル化が必要であるが、詳細なモデル化を行うためには容易に入手できない情報を必要としたり、計算時間が増大したりしてしまう。

例えば、宇田川ら[13]は上記の圧縮機・蒸発器・凝縮器それぞれをモデル化し、冷水温度・冷却水温度を入力として冷却能力を算出する手法を提示している。しかしこのモデルは蒸発温度と冷却・排水熱量、圧縮機動力の特性曲線や、蒸発器・凝縮器の熱貫流率といった推定の困難な項目が含まれている。また、上田ら[14][15][16]は逆カルノーCOPを基準として理想COPを求め、理想COPに対して様々な損失を考慮した修正係数を除することで推定COPを算出するという手法を提示している。ただし、修正係数の算出に修正係数特性式を入手する必要がある。凝縮器や蒸発器のチューブ汚れによる性能低下は、チューブの熱伝達率の低下による終端温度差（冷媒温度と冷水出口温度の差）の増加が指標として用いられる場合があるため、冷凍機のより細かい検討を行う場合には上記のような詳細なモデル化を行う必要があると考えられる。

その一方で、既往のプログラムの一つである Energy Plus [17]や Modelica Buildings Library [7]では性能曲線（負荷率－COP 曲線）が用いられている。そのため本研究においてもこの性能曲線を用いることとした。COP (Coefficient of Performance) は以下のように定義される。なお、本研究における冷凍機 COP はポンプや冷却塔などの消費電力を含まない単体 COP を指す。

$$COP = \frac{\text{Heat production}}{\text{Power consumption}} \quad \text{Eq. (3-1)}$$

Where COP is the coefficient of performance [-].

性能曲線 (Fig. 3-2) の関数を f_{COP} 、負荷率を Pl 、冷却水出口温度を $T_{cn,out}$ とすると、式 Eq. (3-2) のように表される。

$$COP = f_{COP}(Pl, T_{cn,out}) \quad \text{Eq. (3-2)}$$

Where is $f_{COP}()$ the function that is depicted in Fig. 3-2, Pl is the partial load, and $T_{cn,out}$ is the condenser water outlet temperature [$^{\circ}\text{C}$].




Fig. 3-2 TR3 (Office A) performance curves

このとき、入力値となる冷却水出口温度は未知数であり負荷率 Pl 、 COP 、冷却水入口温度 $T_{cn,in}$ 、冷却水流量 G_{cn} によるエネルギーバランスから算出される (Eq. (3-3))

$$T_{cn,out} = f_{T_{cn,out}}(Pl, COP, T_{cn,in}, G_{cn}) \quad \text{Eq. (3-3)}$$

Where $f_{T_{cn,out}}()$ is the function that leads the condenser water outlet temperature considering energy balance of chilled water, condenser water and power consumption, $T_{cn,in}$ is the condenser water inlet temperature [$^{\circ}\text{C}$], and G_{cn} is the condenser water flow rate [m^3/min].

式 Eq. (3-2), Eq. (3-3)において収束計算を行うことで、冷却水入口温度・冷却水流量・負荷率から COP ・冷却水出口温度を算出することができる。なお、Energy Plus における収束条件は冷却水出口温度の前ステップとの偏差が 0.0001°C 以下であった。そのため、本研究でも同様の収束条件を採用した。

3.2.2. 冷却塔

事務所 A には密閉式冷却塔が，工場 B には開放式冷却塔が導入されている。事務所 A の密閉式冷却塔は下水熱利用の予備として設置されているものであるため，本節では開放式冷却塔のモデルについて記述する。冷却塔の熱に関する基礎式は以下のように表される[18]。

$$d\dot{Q}_{total} = \frac{UdA}{c_p}(h_s - h_a) \quad \text{Eq. (3-4)}$$

Where h_s is the enthalpy of saturated air at the wetted-surface temperature [J/kg], h_a is the enthalpy of air in the free stream [J/kg], c_p is the specific heat of moist air [J/kg-°C], U is the cooling tower overall heat transfer coefficient [W/m²-°C], and A is the heat transfer surface area [m²].

ただし，式 Eq. (3-4)は空気や蒸気は理想気体としてふるまう，ファンの熱は無視するといった仮定をおいている。また，湿り空気の比熱は湿球温度の関数で，Eq. (3-5)に示される空気平均比熱 \bar{c}_{pe} と同等のものとして扱う。

$$\bar{c}_{pe} = \frac{\Delta h}{\Delta T_{wb}} \quad \text{Eq. (3-5)}$$

Where Δh is the enthalpy difference between the air entering and leaving the tower [J/kg], and ΔT_{wb} is the wet-bulb temperature difference between the air entering and leaving the tower [°C].

水の熱抵抗は空気よりも非常に大きいため熱交換部の濡れた部分において，表面温度は水の温度になるという仮定を置いている。式 Eq. (3-4)，Eq. (3-5)より，全体的な伝熱の式は Eq. (3-6)，Eq. (3-7)のようになる。

$$d\dot{Q}_{total} = U_e dA(T_w - T_{wb}) \quad \text{Eq. (3-6)}$$

$$U_e = \frac{U\bar{c}_{pe}}{c_p} \quad \text{Eq. (3-7)}$$

Where T_{wb} is the wet-bulb temperature [°C], and T_w is the temperature of the water [°C].

水側と空気側のエネルギーバランスは式 Eq. (3-8), Eq. (3-9)で表される。

$$d\dot{Q}_{total} = \dot{m}_w c_{pw} dT_w \quad \text{Eq. (3-8)}$$

$$d\dot{Q}_{total} = \dot{m}_a \bar{c}_{pe} dT_{wb} \quad \text{Eq. (3-9)}$$

Where \dot{m}_w is the mass flow rate of water [kg/s], c_{pw} is the specific heat of water [J/kg-°C], and \dot{m}_a is the mass flow rate of air [kg/s]

冷却水の単位時間当たりの熱容量 $\dot{m}_w c_{pw}$ が空気のそれ $\dot{m}_a \bar{c}_{pe}$ よりも小さいと仮定すると、冷却塔効率 ε は Eq. (3-10)で表される。

$$\varepsilon = \frac{T_{w,in} - T_{w,out}}{T_{w,in} - T_{wb,in}} \quad \text{Eq. (3-10)}$$

Where $T_{w,in}$ is the inlet water temperature [°C], $T_{w,out}$ is the outlet water temperature [°C], and $T_{wb,in}$ is the wet-bulb temperature of the inlet air [°C].

以上の式より、伝熱面積で積分すると、式 Eq. (3-11)の冷却塔効率が得られる。

$$\varepsilon = \frac{1 - \exp\left[-NTU \left(1 - \frac{\dot{C}_w}{\dot{C}_a}\right)\right]}{1 - \frac{\dot{C}_w}{\dot{C}_a} \exp\left[-NTU \left(1 - \frac{\dot{C}_w}{\dot{C}_a}\right)\right]} \quad \text{Eq. (3-11)}$$

Where $\dot{C}_w = \dot{m}_w c_{pw}$ and $\dot{C}_a = \dot{m}_a \bar{c}_{pe}$

なお、 NTU は式 Eq. (3-12)で表される。

$$NTU = \text{Number of Transfer Units} = \frac{UA_e}{\dot{C}_w} \quad \text{Eq. (3-12)}$$

以上より、冷却水出口温度を求めることができるが、空気出口湿球温度を仮定しなければならぬため、収束計算が必要となる。そのためシミュレーションでは収束計算を行って冷却水出口温度を算出した。なお、収束条件は空気出口湿球温度の前ステップとの偏差が 0.01°C 以下とした。

3.2.3. プレート式熱交換器

向流型の水-水プレート式熱交換器の熱流は Fig. 3-3 のように図示される。ここで、伝熱量に関する Eq. (3-13), Eq. (3-14), Eq. (3-15) が成り立つ。




Fig. 3-3 Cross counter plate heat exchanger

$$dQ = K(T_h - T_c)dA \quad \text{Eq. (3-13)}$$

$$dQ = -G_h c_{p,h} dT_h \quad \text{Eq. (3-14)}$$

$$dQ = -G_c c_{p,c} dT_c \quad \text{Eq. (3-15)}$$

Where dQ is the heat transfer at the minute section [W], dA is the minute section [m^2], T_h and T_c are the hotter and cooler water temperature [$^{\circ}\text{C}$] at dA , G_h and G_c are the mass flow rate [kg/s] of the hotter and the cooler water respectively, $c_{p,h}$ and $c_{p,c}$ are the specific heat at constant pressure [J/(kg·K)] of the hotter and the cooler water respectively, and dT_h and dT_c are the temperature difference [$^{\circ}\text{C}$] of the hotter and the cooler water at dA .

なお、熱貫流率 K [$\text{W}/(\text{m}^2 \cdot \text{K})$] は高温側、低温側の熱伝達率 α_h , α_c [$\text{W}/(\text{m}^2 \cdot \text{K})$] を用いて Eq. (3-16) のように表される。

$$\frac{1}{K} = \frac{1}{\alpha_h} + \frac{1}{\alpha_c} \quad \text{Eq. (3-16)}$$

Where K is the coefficient of overall heat transfer [$\text{W}/(\text{m}^2 \cdot \text{K})$], and α_h and α_c are heat transfer coefficient of the hotter and the cooler water respectively [$\text{W}/(\text{m}^2 \cdot \text{K})$].

また，高温側，低温側の熱伝達率 α_h ， α_c は次式によって算出される[19]。

$$\frac{\alpha}{c_p(G/A)} \left(\frac{c_p \mu}{\lambda} \right)^{2/3} = \frac{0.023}{\{De(L/A)/\mu\}^{0.2}} \quad \text{Eq. (3-17)}$$

Where μ is the viscosity [kg/(m·s)], $De = 2ab/(a + b)$, and a and b is the flow path length and width respectively [m].

以上の式を流量と入口温度を入力変数，出口温度を出力変数となるよう変形することでシステムシミュレーションにて利用可能なモデルとした。

なお，出口温度の算出に用いられる熱貫流率 K は定圧比熱，密度（体積流量から重量流量の算出に用いる），粘度が必要なパラメータとして Eq. (3-17)に記述されているが，これらのパラメータは温度の関数である。温度の代表点として，入口温度と出口温度の平均をその計算ステップにおける温度とする場合，まず出口温度を仮定し，仮定した出口温度と計算結果の出口温度が指定した範囲内で一致するよう収束計算を行う必要がある。しかし，シミュレーション中では収束計算を行うのではなく，定圧比熱，密度，粘度といったこれらパラメータを算出するための出口温度は入口温度に対して 2℃ 差という仮定をおいて算出した。

3.2.4. 水蓄熱槽

事務所 A の熱源システムに導入されている蓄熱槽は、深さ 6m の成層型蓄熱槽であるため、槽内を完全混合域と一次元拡散域とに分割する混合モデルを用いてモデル化を行った [20] [21]。蓄熱槽を高さ方向に 1,200 分割し、流入側の端層を完全混合域、その他の層を一次元拡散域とした。

完全混合域における温度 T_1 は、入口温度 T_{in} 、高さ方向の流速 U 、時間 t 、一層当たりの高さ Lp を用いて Eq. (3-18)のように表される。

$$T_1 = T_{in}(1 - e^{-Ut/Lp}) \quad \text{Eq. (3-18)}$$

Where T_1 is the temperature at the mixed layer [°C], T_{in} is the inlet temperature [°C], U is the flow velocity on the vertical direction [m/s], t is the time interval [s], and Lp is the height per one layer [m].

一次元拡散域における温度 T は分子拡散レベルの乱流拡散係数 κ_0 、高さ z を用いて式 Eq. (3-19)のように表される。

$$\frac{\partial T}{\partial t} = \kappa_0 \frac{\partial^2 T}{\partial z^2} - U \frac{\partial T}{\partial z} \quad \text{Eq. (3-19)}$$

Where T is the temperature at the one-dimensional diffusion layer [°C], κ_0 is the turbulent diffusion coefficient [m²/s], and z is the height of the layer [m].

なお、1 計算時間あたりの高さ方向の進行が分割幅よりも大きい場合は、水が進行方向に押し出されるとして計算を行った。

3.2.5. ポンプ

ポンプは圧力を与えることで配管内の圧力を制御する，またはその結果として流量を制御する機器である。ポンプの特性は流量－全揚程特性曲線と流量－効率特性曲線の 2 種類の特性曲線から得ることができる (Fig. 3-4)。




Fig. 3-4 Pump specification curves

ただし，Fig. 3-4 の曲線はポンプインバータ周波数が定格比 100%時のものである。ポンプインバータ周波数比を (0~1) を INV とした時，各曲線は INV に従い変形される[22]。

流量－全揚程特性曲線に関して，まず流量・揚程と INV の関係は Eq. (3-20)，Eq. (3-21) に従う。

$$G_{INV} = INV \cdot G \quad \text{Eq. (3-20)}$$

$$H_{INV} = INV^2 \cdot H \quad \text{Eq. (3-21)}$$

Where G is the flow rate with pump frequency rate 100% [m³/min], INV is the pump inverter frequency rate [%], G_{INV} is the flow rate with pump frequency rate INV [m³/min].

これを定格時の流量と圧力の関係式 Eq. (3-22)に適用すると、 INV 変化時の圧力は流量の式 Eq. (3-23)と記述される。

$$H = f_a(G) \quad \text{Eq. (3-22)}$$

$$H_{INV} = f_a\left(\frac{G_{INV}}{INV}\right) \cdot INV^2 \quad \text{Eq. (3-23)}$$

Where H is the total head with pump frequency rate 100% [kPa], $f_a()$ is the relationship between flow rate and total head depicted in Fig. 3-4, and H_{INV} is the total head with pump frequency rate INV [kPa].

流量－効率特性曲線も INV によって変形される。定格時の最大効率を η_{max} とした時、 INV 周波数が変化したときの最高効率 $\eta_{max_{INV}}$ は Eq. (3-24)で表される。

$$\eta_{max_{INV}} = 1 - \frac{1 - \eta_{max}}{INV^{1/5}} \quad \text{Eq. (3-24)}$$

Where η_{max} is the maximum efficiency with pump frequency rate 100% [%], and $\eta_{max_{INV}}$ is the maximum efficiency with pump frequency rate INV [%]

これを定格時の流量と効率の関係式 Eq. (3-25)に適用すると、 INV 変化時の効率は流量の式 Eq. (3-26)と記述される。

$$\eta = f_b(G) \quad \text{Eq. (3-25)}$$

$$\eta_{INV} = f_b\left(\frac{G_{INV}}{INV}\right) \cdot \frac{\eta_{max_{INV}}}{\eta_{max}} \quad \text{Eq. (3-26)}$$

Where $f_b()$ is the relationship between flow rate and efficiency depicted in Fig. 3-4.

以上を用いると、ポンプ動力 P_w [W]が算出できる(Eq. (3-27))。なお、本シミュレーションではモーター損失を 0.9 と仮定した。

$$P_w = \frac{g \cdot \rho \cdot G_{INV} \cdot H_{INV}}{\eta_{INV} \cdot \eta_{motor}} \quad \text{Eq. (3-27)}$$

Where g is the gravitational acceleration [m/s²], ρ is the density of water [kg/m³], η_{motor} is the motor efficiency [%].

3.2.6. 弁

弁は圧力損失を生じさせることで配管内圧力を制御する，またはその結果として流量を制御する機器である。そこで，任意の弁開度に対する流量と圧力損失の関係をモデル化した。弁前後における圧力損失が一定になるような弁開度と流量の関係は固有流量特性と呼ばれ，代表的な固有流量特性にリニア特性，イコールパーセント特性がある（Fig.3-5）。建築設備には制御性を考慮してイコールパーセント特性の弁が用いられることが多いため[23]，以下ではイコールパーセント特性の弁について述べる。




Fig. 3-5 Valve inherent flow characteristics

調節弁において，弁前後における圧力損失を一定とした場合の制御可能な流量 G [kg/s]の最小値 G_{min} と最大値 G_{max} の比は固有レンジアビリティ R と呼ばれる[24]。

$$R = \frac{G_{max}}{G_{min}} = \frac{Cv_{max}}{Cv_{min}} \quad \text{Eq. (3-28)}$$

Where R is the range ability, G_{max} and G_{min} are the maximum and minimum flow rate that can be controlled, respectively, Cv_{min} and Cv_{max} are the flow coefficient with fully closed and open, respectively.

本シミュレーションでは、機器仕様として R の値を入手できなかったため、適宜 R を決定した ($R = 100$ など)。また、 Cv は流量係数 (flow coefficient または valve coefficient) と呼ばれるもので、1 Cv のとき、”one U.S. gallon (3.78 liters) of 60°F (16°C) water that flow through an opening, such as a valve, during 1min with a 1-psi (0.1-bar) pressure drop” (60°F の 1 ガロンの清水が弁の差圧を 1psi に保って 1 分間で流れる) と定義される[25]。 Cv_{min} は弁が全閉時の流量係数で、 Cv_{max} は弁が全開時の流量係数である。

イコールパーセント特性において、任意の弁開度 S に対する流量係数 Cv は Eq. (3-29)のよう表される。なお、 S_{max} は弁の全開時開度を意味する。

$$Cv = Cv_{max} R \left(\frac{S}{S_{max}} - 1 \right) \quad \text{Eq. (3-29)}$$

Where S is the valve opening, S_{max} is the maximum valve opening, Cv is the flow coefficient with valve opening S .

上式から、流量比が $0 \sim 1/R$ である場合は弁開度による制御を行うことができない (ON-OFF 制御となる) ことが分かる。

また、リニア特性の場合は Eq. (3-30)のよう表される。

$$Cv = Cv_{max} \frac{S}{S_{max}} \quad \text{Eq. (3-30)}$$

以上より、流量係数 Cv と弁の圧力損失 ΔP_v [kPa]の関係は Eq. (3-31)により表される。

$$Cv = \frac{11.6W}{\sqrt{\frac{\rho}{\rho_w} \Delta P_v}} \quad \text{Eq. (3-31)}$$

Where ρ_w is the density of water [kg/m³], ρ is the density of the fluid [kg/m³], and W is the mass flow [T/h].

シミュレーションには Eq. (3-31)の流量と圧力損失との関係を組み込んだ。以上の弁特性を導入することで、レンジアビリティと流量係数を機器特性値とし、任意の弁開度と流量から圧力損失を算出可能とした。

3.3. 水搬送系モデル

3.3.1. 流量バランス計算の基礎理論

水搬送系モデル（流量計算）を原理的に解くことは本シミュレーションの特徴の一つである。時刻ごとに定常状態になると仮定し、ポンプによる加圧と配管や機器による圧力損失が釣り合う点を算出する。この流量バランス計算は、電気回路における Kirchhoff's circuit laws のアナロジーであり、以下の2つのルールに従う。

1. 任意の節点において、流入する量の総和と流出する量の総和が等しい。

$$\sum_{i=1}^N G_i = 0 \quad \text{Eq. (3-32)}$$

Where G_i is the flow that inflows into or outflows from one point, and N is the number of branches that connect to the point.

2. 任意の閉ループにおいて、圧力の向きを一方向にとったとき、その圧力の総和は 0 である。

$$\sum_{i=1}^N P_i = 0 \quad \text{Eq. (3-33)}$$

Where P_i is the pressure that is added or dropped within a branch, and N is the number of branches that constitutes a closed loop.

なお、圧力損失は Darcy–Weisbach Equation (Eq. (3-34)) を用いた。本式は圧力損失が流速の二乗に比例する式であるが、流量が流速を断面積で除した値であり、断面積は流速によって変化しないことを考慮し、本シミュレーションでは圧力損失を流量の二乗に比例するものとした。

$$\Delta p_f = \lambda \frac{\rho v^2}{2 D} \quad \text{Eq. (3-34)}$$

Where Δp_f is the pressure drop (Pa), λ is the Darcy friction factor, ρ is the density of the fluid [kg/m³], v is the flow velocity [m/s], D is the hydraulic diameter [m].

3.3.2. モデル例

Fig. 3-6 に流量バランス計算におけるモデルの例（基本モデル）を示す。本モデルは配管、ポンプ、機器、膨張タンクのみを有する単純なモデルである。ここでの機器とは、熱交換器や冷凍機など、圧力損失を伴う機器を想定している。膨張タンクが接続する点で基本モデルを展開し、その圧力分布を Fig. 3-6 右部に示す。Eq. (3-33) より、基本モデルの始端と終端の圧力は一致する。つまり、ポンプで加圧された圧力と、機器や配管の圧力損失との和が 0 になるような流量がこの系における流量である。その流量は、ポンプ特性、機器や配管の圧力損失特性を用いて算出できる（Fig. 3-7）。なお、ポンプは直列の場合圧力方向に曲線が加算され、並列の場合は流量方向に曲線が加算されるものとした。

流量計算は本シミュレーションの中で最も計算時間を要する部分である。系の分岐が多くなると計算時間が増大するが、本研究で対象とした熱源システムは二次側の AHU を一台と簡略化して配管システムをモデル化することで、計算時間の長大化を回避した。




Fig. 3-6 Basic model for flow balance calculation

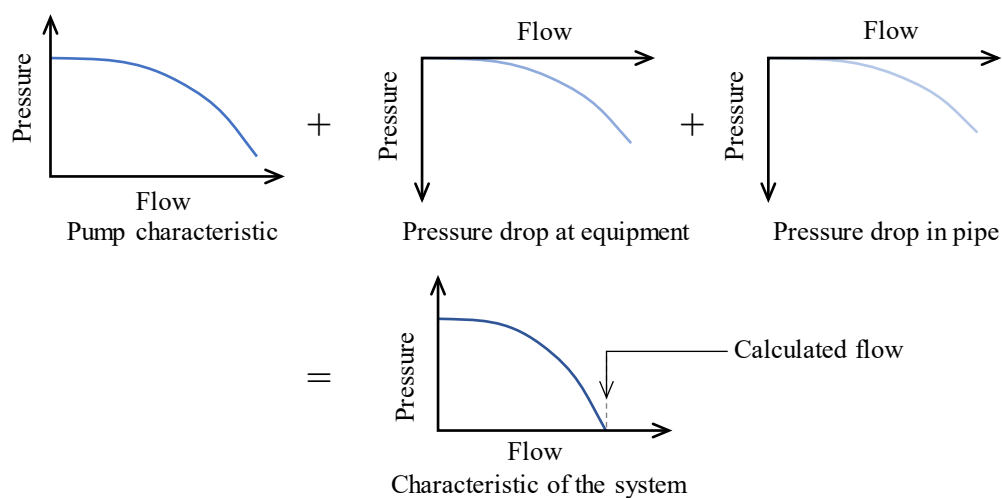


Fig. 3-7 Concept of calculation for the basic model

3.3.3. 数値解法（二分法・ニュートン法）

本研究における流量バランス計算はすべて二分法を用いて求解した。二分法とは、ある関数 $y = f(x)$ に対して逆関数 $x = f^{-1}(y)$ を数値計算により解く際に用いられる手法である。ただし、凸な関数には適用に制限があり、また解が存在する範囲をあらかじめ仮定する必要がある。なお、ポンプ特性や圧力損失の式が1次式で表現できるとすれば行列により解を求めることができるが、圧力損失は2次式、ポンプ特性は2次以上の近似式であるため、二分法やニュートン法が必要となる。

Fig. 3-8 に例を示す。ある関数 $y = f(x)$ に対して、 $y = 0$ の時の x を求めることとする。まず、ある範囲 ($\min < x < \max$) に解が存在すると仮定して、 x が \min と \max の平均値 (ave) の時の y の値 $f(ave)$ を求める。その $f(ave)$ が正の時、 \min を ave に設定しなおし、 $f(ave)$ が負の時、 \max を ave に設定しなおす。これを繰り返すことによって ave は解に近づくため、 $f(ave)$ が設定した収束条件を満たした時に繰り返し計算を終了し、その時の ave を近似解とする。なお、収束条件は各ループにおける流量最大値に対して 0.5% 程度の値とした。




Fig. 3-8 Bisection method

ニュートン法も二分法と同様に $f(x) = 0$ を満たす x を探索する手法である。まず適当な初期値 x_0 を取り、漸化式 Eq. (3-35)を用い、収束した x を解とする。

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)} \quad \text{Eq. (3-35)}$$

Where x_n is the candidate at the step n , and $f()$ is the function to be solved.

ニュートン法は二次収束するため解の収束が速いという特徴があるが、初期値の設定によっては不適切な解（負の値など）を算出してしまう可能性がある。そのため、流量バランス計算には解の範囲を最初に指定できる二分法を採用した。

3.4. 制御モデル

3.4.1. PID 制御

PID (Proportional-Integral-Differential) 制御とは, 偏差 (目標値と制御対象の測定値との差) の大小に応じて修正する比例 (P) 動作, オフセットを除去するための積分 (I) 動作, 偏差の増減を反映して応答を改善する微分 (D) 動作から構成されるフィードバック制御である。PID 調節器の制御則は式 Eq. (3-36) のように表される。

$$u(t) = K_p \left(e(t) + \frac{1}{T_I} \int e(t) dt + T_D \frac{de(t)}{dt} \right) \quad \text{Eq. (3-36)}$$

Where $u(t)$ is the control output, K_p is the proportional gain, T_I is the integral time, T_D is the derivative time, and $e(t)$ is the error value.

空調システムでは微分項を無視した PI 制御が主に導入されている。理由としては, 例えば流量制御には流量ノイズが存在することや, 温度制御における時間遅れが挙げられる。そこでシミュレーションでは離散化した PI 制御 (Eq. (3-37)) を組み込み制御システムを構築した。

$$u_n = K_p \left(e_n + \frac{1}{T_I} \sum_{i=0}^n e_i \Delta T \right) \quad \text{Eq. (3-37)}$$

Where u_n is the control output at the time step n , and e_i is the error value at the time step i .

本シミュレーションは計算時間間隔が 1 分間であるが, 実際の PI 制御のサンプリング時間は秒単位の場合もあるため, シミュレーションに入力される比例ゲインと積分時間は実際のシステムとは異なることに留意する必要がある。サンプリング時間を実システムとシミュレーションとで一致させることによる, 本シミュレーションのさらなる実用可能性の向上は今後の課題である。しかし, 本研究では 1 分間隔の計算でも十分にフィードバック制御による制御の過渡状態が表現可能となるとして検討を行った。

3.4.2. 台数制御

熱源システムにおいて、ポンプや冷凍機の運転台数は負荷状況によって適宜変更される。流量を参照する台数制御の場合、流量が一定時間増段閾値（g12）以上になった場合に増段し、一定時間減段閾値（g21）以下になった場合に減段する（Fig. 3-9）。この一定時間は効果待ち時間と呼ばれ、ポンプでは 5 分、冷凍機の場合は 15 分とした。増段閾値と減段閾値に設けられたギャップは、頻繁な増減段の発生を防ぐ工夫である。




Fig. 3-9 Operation number control

3.4.3. 全体制御

事務所 A の熱源システムは蓄熱槽を有し、夜間蓄熱・昼間放熱の運転がなされている。22:00 に残蓄熱量を考慮して冷凍機の運転台数と負荷率を決定し、昼間に残蓄熱量が不足した場合は追掛け運転を行う。事務所 A の熱源システムに導入されている冷凍機は 4 台あるが、それぞれ特性や設置状況が異なる。そのため、蓄熱時に COP が最も高くなるような負荷率と台数が設定される。

工場 B は負荷に応じて冷凍機と二次ポンプの台数制御が行われる。冷却水ポンプ制御第 2 章 2.6.節を参照されたい。また、冷却塔における冷却水出口温度は、外気湿球温度+4°C となるように冷却塔ファンが制御される。冷却水温度が低すぎると冷凍機の安定運転に支障をきたすため、外気湿球温度が低い場合は冷凍機冷却水入口温度が下限値となるよう冷却水バイパス弁が制御される。

3.5. システムモデル

上述の機器モデル、水搬送系モデル、制御モデルを一つのプログラムとして接続することでシステム全体の挙動を算出できるシステムモデルを構築した (Fig. 3-10)。本シミュレーションを実行するにあたり、入力値は熱負荷と下水温度や外気湿球温度といった境界条件のみである。これらに基づき、事前に設定された制御ロジックに従い設定値が決定され、その設定値を満たすよう機器台数制御や PI 制御が実行される。PI 制御によって決定されたポンプインバータ周波数と弁開度に基づき配管内の流量が算出され、流量と熱負荷・前時刻の温度に基づき機器や配管内の温度が算出される。この計算が 1 分間隔で繰り返される。

本研究における検討内容から、制御の過渡状態、つまり設定値や負荷が変動するなかでポンプ等のフィードバック制御を可能とすることが必要であった。1 分間という計算時間間隔はこのようなフィードバック制御を表現するためには最低限必要な時間間隔であり、適切だと考えられる。なお、PI パラメータを実システムと一致させるためには計算時間間隔を制御周期と一致させる必要があるため数秒とするとともに、機器モデル等で時間遅れをより適切にモデル化することが必要であることに留意すべきである。

冷凍機の台数制御において、事務所 A では蓄熱制御の概念が組み込まれる一方、工場 B では負荷に応じた制御が行われるという違いはあるが、両者ともこのフローに従って計算を行った。なお、第 7 章におけるモデル予測制御では、冷凍機台数制御の部分が設計時のロジックに従うのではなく提案する手法に従うものとした。

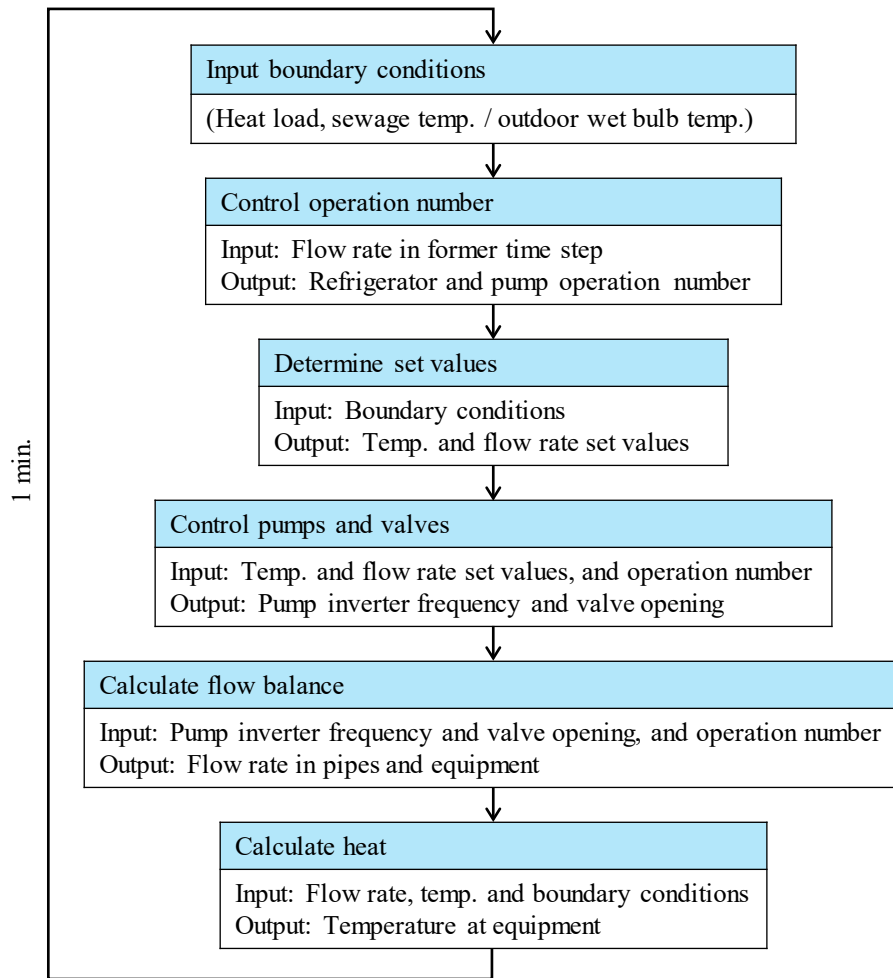


Fig. 3-10 System model calculation flow

3.6. 計算結果例

事務所 A の代表週における二次冷水流量と同行き温度の計算結果と BEMS データとの比較を示す (Fig. 3-11)。対象とした期間は 1 分間隔の BEMS データが保存されていたため、シミュレーション結果と直接の比較を行った。

本シミュレーションは BEMS データにおける負荷を入力とするため、二次冷水流量がほぼ一致するのは当然であるが、ポンプや冷凍機の台数制御に伴う流量や温度の立ち上がりもシミュレーション結果と BEMS データは似た挙動をしている。そのため、本シミュレーションプログラムは制御の過渡状態を算出可能であるとして第 4 章以降の検討を行った。

なお、計算結果と BEMS データとが一致するようにプログラムのキャリブレーションを行うことはしなかった。本研究は、実運用におけるシステムは不具合を有し、BEMS データは不具合の影響を受けているという前提のもとに遂行されている。プログラムを BEMS データに合わせてキャリブレーションした場合、設計時に想定された挙動とは異なる挙動になってしまうとみなすためである。




Fig. 3-11 Example of the simulation results in a week

3.7. 小括

本章では、不具合検知・診断や最適制御に活用するために制御の過渡状態を表現することを目的として、熱源システムの詳細なシミュレーションプログラムを構築した。機器モデルは性能曲線や物理原理に基づき、流量計算は配管内圧力を考慮した流量バランス計算に従うものとした。制御に関しては台数制御やPI制御を組み込み、計算時間間隔を1分間とすることで負荷等の入力条件に対するフィードバック制御を可能とした。

流量バランス計算によって、ポンプインバータ(INV)周波数や弁開度といった機器の制御量と、圧力・流量やそれに伴う温度が原理的に変化し、さらにポンプ全揚程も算出することができる。そのためポンプ消費電力も理論的に計算することができる。一方、BESTやLCEMといった既存シミュレーションプログラムは圧力分布を解いていないためフィードバック制御を正しくモデル化できず、ポンプ消費電力も近似解しか得られない。そのため、第4章以降のような制御の過渡状態を必要とする検討を行うことはできないと考えられる。

モデル構築は目的に応じていることが重要である。本研究では第5・6章における不具合検知・診断のための不具合データベースを作成することが大きな目的の一つである。そのためには診断したい不具合によるシステム挙動の特徴を算出する必要がある。機器仕様書や設計図書に従いシステムシミュレーションを構築することでこの目的は達成できていると考えている。ただし、システム本来の挙動を表すシミュレーションを構築するという目的に際しては、現在は実際のシステムが設計図書や機器仕様書に従うという仮定を与えている。実システムと設計図書は施工段階にて乖離する場合があるため、実システム本来の挙動を表すモデル構築には何らかの手法開発が今後の課題として必要であろう。

本研究におけるプログラムでは、配管内の水搬送の遅れや機器の熱容量といった動的モデル、センサの通信時間遅れ等はモデル化の対象外とした。PI制御はこのような遅れの影響を受けるため、実システムに適用可能な最適PIパラメータを決定するといった検討にはこれらの遅れを考慮したモデル化が必要と考えられる。

なお、本シミュレーションプログラムは機器モデル・水搬送系モデル・制御モデルを組み上げることでシステムモデルを構築するという概念の上に構築したものである。そのため、本研究にて対象としたシステムとは異なる構成のシステムであっても、機器モデルのパラメータを変更し、水搬送系モデルの連立方程式を設定し、制御モデルを更新することでプログラムの作成は可能である。ただし、水搬送系モデルにおいて系固有の連立方程式を設定する際は労力を要するため、より簡易に連立方程式を設定可能とすることは今後の課題である。

参考文献

- [1] Haves P., Dexter A. L., Jorgensen D. R., Ling K. V., Geng G. : Use of a building emulator to develop techniques for improved commissioning and control of HVAC systems, ASHRAE Transactions, Vol. 97, No. 1, pp.684-688, 1991.
- [2] Bushby Steven T., Galler Michael A., Ferretti Natascha Milesi, Park Cheol : The virtual cybernetic building testbed—a building emulator, ASHRAE Transactions, Vol. 116, No. 1, pp.37-44, 2010.
- [3] Lee Edward A. : Cyber physical systems: Design challenges, pp.363-369, 2008.
- [4] Park Cheol, Clark Daniel R., Kelly George E. : An overview of HVACSIM , a dynamic building/HVAC/control systems simulation program, pp.21-22, 1985.
- [5] Crawley Drury B., Lawrie Linda K., Winkelmann Frederick C., Buhl Walter F., Huang Y. Joe, Pedersen Curtis O., Strand Richard K., Liesen Richard J., Fisher Daniel E., Witte Michael J. : EnergyPlus: creating a new-generation building energy simulation program, Energy and Buildings, Vol. 33, No. 4, pp.319-331, 2001.
- [6] Beckman William A., Broman Lars, Fiksel Alex, Klein Sanford A., Lindberg Eva, Schuler Mattias, Thornton Jeff : TRNSYS The most complete solar energy system modeling and simulation software, Renewable Energy, Vol. 5, No. 1, pp.486-488, 1994.
- [7] Wetter Michael, Zuo Wangda, Noudui Thierry S., Pang Xiufeng : Modelica buildings library, Journal of Building Performance Simulation, Vol. 7, No. 4, pp.253-270, 2014.
- [8] 村上周三, 松尾陽, 坂本雄三, 石野久彌, 大塚雅之, 赤坂裕, 滝澤総, 野原文男 : OS-18 外皮・躯体と設備・機器の総合エネルギーシミュレーションツール「BEST」の開発 (その 1): BEST 開発の背景と趣旨, pp.1969-1972, 2007.
- [9] 時田繁, 松縄堅, 丹羽英治, 杉原義文, 岡崎徳臣 : F-52 ライフサイクルエネルギーマネージメントのための空調システムシミュレーション開発:(第 1 報) LCEM (ライフサイクルエネルギーマネージメント) の枠組み, pp.1957-1960, 2005.
- [10] 国立研究開発法人建築研究所 HP :建築物のエネルギー消費量計算プログラム (非住宅版) , <https://building.app.lowenergy.jp/> (2019 年 9 月 25 日閲覧)
- [11] Judkoff Ron, Neymark Joel : International Energy Agency building energy simulation test (BESTEST) and diagnostic method, International Energy Agency building energy simulation test (BESTEST) and diagnostic method, 1995.

- [12] Bourdouxhe Jean-Pascal, Lebrun Jean, Grodent Marc : Reference guide for dynamic models of HVAC equipment, American Society of Heating, Refrigerating and Air-Conditioning Engineers 1998.
- [13] 宇田川光弘, 村田太市 : 空調システムシミュレーションのための圧縮式冷凍機の計算モデル, 空気調和・衛生工学会 論文集, 第22巻, 第64号, pp.73-82, 1997.
- [14] 上田憲治, 梶野良枝, 下田吉之 : B-3 ターボ冷凍機部分負荷性能推定手法の開発:(第1報) 性能推定手法の概要と実用化, pp.93-96, 2010.
- [15] 高山紗輝, 赤司泰義, 桑原康浩, 上田憲治, 梶野良枝 : B-4 ターボ冷凍機部分負荷性能推定手法の開発:(第2報) 性能推定手法の簡易性能評価ツールへの導入と効果, pp.97-100, 2010.
- [16] 長谷川泰士, 梶野良枝, 上田憲治 : E-45 ターボ冷凍機部分負荷性能推定手法の開発:(第3報) 熱交換器性能の組込みによる推定手法精度の向上, pp.1279-1282, 2011.
- [17] U. S. Department of Energy : Energyplus Version 8.9.0 Documentation Engineering Reference, pp.767-773, March 23, 2018.
- [18] U. S. Department of Energy : Energyplus Version 8.9.0 Documentation Engineering Reference, pp.982-989, March 23, 2018.
- [19] 井上宇市 編 : 空気調和ハンドブック, 丸善出版株式会社 平成26年.
- [20] 辻本誠, 相良和伸, 中原信生 : 蓄熱槽に関する研究: 第1報-成層型蓄熱槽の槽内混合機構に関する実験的研究, 空気調和・衛生工学会 論文集, 第6巻, 第16号, pp.23-35, 1981.
- [21] 相良和伸, 辻本誠, 中原信生 : 蓄熱槽に関する研究: 第2報-数値シミュレーションによる成層型蓄熱槽の槽内混合機構についての研究, 空気調和・衛生工学会 論文集, 第6巻, 第17号, pp.29-39, 1981.
- [22] 外山幸雄 : 絵とき「ポンプ」基礎のきそ-選定・運転・保守点検-, 日刊工業新聞社 2014.
- [23] 加古五郎 : 調節弁 (2): 弁の形式と流量特性, 計測, 第7巻, 第7号, pp.400-405, 1957.
- [24] 千葉孝男, 井口泰男, 渡辺宏 : 配管・ダクト系の制御特性, 空気調和・衛生工学, 第72巻, 第5号, pp.391-397, 1998.
- [25] Skousen Phillip L. : Valve handbook, McGraw-Hill, 2011.

第4章

不確かさを考慮した不具合検知

4.1. 本章の背景と目的

4.1.1. 既往の FDD と不確かさ

空調システムにおける不具合検知・診断 (FDD) の重要性は序論にて述べたとおりであり、そのため数多くの研究がなされてきた。一般的に、これら FDD 手法は定性的モデルベース手法、定量的モデルベース手法、過去データベース手法の3パターンまたはこれらの組み合わせに分類される[1] [2] [3]。各手法は当然のことながら BEMS において収集されたデータを解析対象とする。そのため、FDD を行う際には BEMS データが影響を受けているノイズやセンサの不確かさを考慮する必要がある[4]。対処方法の一つとして欠損や異常値に対するデータクレンジングが挙げられるが[5] [6]，本研究においてデータクレンジングは検討対象外とする。

機器単体の不具合とは異なり、センサ誤差といったセンサの不具合はシステムとしての挙動から検知・診断することが必要となる。例えば、センサ誤差を直接検知するためには同一の箇所に複数のセンサを設置する必要があるが、空調システムではコストを要するセンサの同一箇所の複数設置は一般的ではない。加えて、空調システムは PI 制御等のフィードバック制御により、多少のセンサ誤差が生じてシステムはロバストに制御される。

例として、冷却塔システムにおける冷却水出口温度センサ誤差を不具合の例として考える。この冷却塔システムでは、冷却水出口温度が設定温度になるよう、冷却塔ファンの回転数が PI 制御されるものとする。このセンサが真値に対して 1°C 高く測定してしまう場合、冷却塔ファンは冷却水を設定温度まで冷却するために本来よりも高い回転数で制御され、ファン動力が増加する。外気湿球温度が十分低い場合、センサから得られる値は制御された結果である設定温度となる。このように、空調システムに多少のセンサ誤差が生じた場合、真の値は設定温度には制御されないが、計測されている値からは設定温度通りに制御されているように見える。そのため、センサ誤差の検知は難しい課題である。これを踏まえて様々なセンサ不具合の検知手法が検討されている[7] [8] [9]。しかし空調システムに設置されている数十ものセンサのもつ不確かさを同時に考慮した例はみられない。

測定分野において、不確かさ (uncertainty) は以下のように定義される。

“parameters associated with the result of a measurement, that characterize the dispersion of the values that could reasonably be attributed to the measurand” [10]

「測定の結果に付随した、合理的に測定対象量に結び付けられ得る値のばらつきを特徴づけるパラメータ」 [11]

Wang and Haves [12]は測定の不確かさを考慮することで、FDD 手法のロバスト性を向上させた。また、空調システムに関連する測定の不確かさに関して、建物熱特性のモデル化、熱負荷予測、機器容量選定にて活用する研究がなされている[13] [14] [15]。しかし、制御システムにおける不確かさが性能に与える影響に関する検討はいまだなされていない。

4.1.2. システムレベルの不具合検知

空調システムにおいて、センサはフィードバック制御に用いられるものや、測定のみで用いられるものがある。これらのセンサによって測定された値には不確かさが含まれており、したがってその測定値により制御されるシステムの挙動や、結果として得られる性能の値には不確かさが含まれる。本検討では不確かさの発生源をセンサに加えてアクチュエータ（操作部）と通信機器にも拡大し、これらの不確かさを確率的にモデル化することで、空調システムの制御システムにおける不確かさを考慮することとした。

上述した空調システムにおける不確かさによる影響は、機器単体のみならず複数の制御ループへ同時に非線形に作用する。そのため、不確かさを考慮することでシステムレベルでの性能評価が可能になると考えられる。

システムレベルの不具合検知には、ベンチマークによる性能評価が挙げられる。ベンチマークとは、対象建物のエネルギー消費を床面積や気候帯が同様の他建物と比較するものである[16]。Wang らはコミッショニングの最初の段階でベンチマークを行った[17]。しかし、空調システムは建物が異なれば設計や利用状況も異なり、さらにベンチマークシステムを構築するためのデータベースには不具合が含まれる可能性もある。Sun らは不具合検知における統計処理を改善するために grey-box model を利用した[18]。Wang らや Gao らはシステム全体のデータを利用する FDD 手法を検討した[19] [20]。これらの手法はいくつかの不具合を検知対象とする一方で、不具合の存在そのものをシステムレベルで検知する手法ではない。フィードバック制御は不確かさに対してロバストであるが、二次側へ適切に熱を供給できたとしてもエネルギー効率が数%変化することは十分に考えられるため、システムレベルにおける不確かさを考慮した不具合検知の検討は有意義であると考えられる。

4.1.3. 本章の目的と手法

以上を踏まえ、本章では以下3点を目的として検討を行った。

- ①熱源システムにおける不確かさのモデル化
- ②不確かさを考慮した性能分布の算出
- ③性能分布を用いた不具合検知

これらの目的のために、本章では熱源システムの SCOP (System Coefficient of Performance) を算出対象とした。SCOP とは、熱源システムが供給した熱量を消費した電力量で除した値である。SCOP は熱源システムのエネルギー効率を表す指標であるため、不確かさによってどの程度 SCOP は影響を受けるかを計算によって明らかにする。熱源システムの SCOP は負荷や外気温湿度といった条件によって常に変動するため、条件に応じた理想的な値を参照する必要がある。実際のシステムにはどのような不具合が含まれているか不明であるため、この理想的な値を BEMS データから得ることはできない。一方で物理原理や制御ロジックを適切に反映したシミュレーションによつては理想的な SCOP を得ることができるため、本章の検討ではシミュレーションに不確かさを反映させることとした。

不確かさを考慮した SCOP を算出するために、センサ・アクチュエータ・通信機器における不確かさを確率的にモデル化し、詳細なシステムシミュレーションに組み込んだ。このとき、シミュレーションでは真値を計算するとの前提のもと、不確かさは真値に加算されるノイズとみなして検討を行った。センサ誤差を含むシステムの挙動は EnergyPlus でも算出が可能であるが[21]、不確かさとして確率的にモデル化されたものが直接シミュレーションに組み込まれた例は見られない。空調制御システムにおいて、センサ・アクチュエータ・通信機器は同一の制御ループの中で利用される場合があるため、不確かさは相互作用するはずである。この相互作用を算出可能とした点も本検討の新規性である。

そして、モンテカルロシミュレーションにより不確かさに基づく真値からのノイズを 2,000 通り与え、不確かさによる SCOP の分布を推定した。この分布によって、対象システムに不具合がない場合でも不確かさによって生じうる SCOP の幅が定量的に示されるため、不具合検知に応用可能である。SCOP のみを用いた不具合検知を定量的に可能とした点も本検討の新規性である。

4.1.4. 対象システム

本章の対象システムは、事務所ビル A の熱源システムとする。本システムは蓄熱槽を有するため、各種不確かさによる制御状態への影響や機器性能への影響が、蓄熱槽を有さない工場 B の熱源システムよりも大きいと想定されたためである。

4.2. 不具合検知・診断スキーム

本節では本研究にて提案する不具合検知・診断全体のスキームを提案する。

不具合検知・診断の直接の目的はシステムに生じている不具合を明らかにすることであるが、その結果を保全計画に活用することで不具合を効率的に取り除くことが最終的な目的である。これを踏まえると、Fig. 4-1 に示される 3 つの段階（Detection：検知，Diagnosis：診断，Identification：同定）が必要であると考ええる。

まず、不具合検知によりシステムにおける不具合の有無そのものを SCOP により判断する。ここで何か重大な不具合が生じていることが示唆された場合、次にどのような不具合が生じているかを診断する。そして生じていると診断された不具合の程度（severity, level）を同定することで不具合を修復することによる性能向上を定量化可能とする。

もちろん、検知や診断のプロセスを行わずに最初から不具合を同定することも手法として考えられるが、不具合として想定できる事象は数十以上あり、これらのパラメータを全て同定することは現在の計算機の性能では現実的ではない。そのため、提案するスキームのように順次検知・診断・同定を行うことが適切であると考えられる。

本章では、不具合検知に用いることができる性能分布を算出することを目的としている。第 5 章と第 6 章では不具合検知・診断に着目した検討を行う。第 5 章・第 6 章では不具合診断を行うことで不具合の検知も可能であるため、不具合検知・診断と呼ぶこととした。多くのシステムを同時に管理する場合、不具合検知によって不具合を有すると判断されたシステムから優先的に不具合検知・診断を適用することを想定している。なお、本研究では診断された不具合の同定は検討対象外とした。




Fig. 4-1 Schematic of uncertainties in the heat source system.

4.3. 不確かさのモデル化

4.1 節にて、測定の不確かさの一般的な定義を示した[10]。しかし、シミュレーションを用いた本検討における熱源システムの不確かさを「センサ・アクチュエータ・通信機器の精度に基づき生じる避けられないノイズ値」として定義することとした。

従来の測定の不確かさの定義と本検討における不確かさの定義との違いは、真値の存在の有無である。現実世界の測定において、真値は決して得られない値であるため、測定の不確かさは真値の存在を前提としない表現となっている。その一方で、不確かさを考慮しない決定論的なシミュレーションにおいて、ある時刻における流量や温度といった値は各値が原理的にバランスしており、真値と捉えることが妥当である。そのため、この真値に本検討における不確かさを加算することで、不確かさを考慮した熱源システムの挙動を算出可能と考えた。なお、本検討における不確かさ（以下、不確かさ）は各種機器精度に起因するものであるため、不具合とはみなされないことに留意する必要がある。

熱源システムにおける不確かさは Type 1 から Type 3（センサ・アクチュエータ・通信機器）の 3 種類に分けることができる（Fig. 4-2）。アクチュエータとは制御対象であり、熱源システムにおいては弁開度やポンプ回転数を指す。BEMS によって収集されたデータ、つまりモニタリングやデータ解析に利用可能なデータはこれらの不確かさによる影響を受けた結果であるとみなすことができる。

本検討において、各種不確かさは Fig. 4-2 に従ってシミュレーションプログラムに組み込むこととした。本シミュレーションの新規性は、真値と不確かさを含む値とを両方算出し、その結果として不確かさによる相互作用を含む様々な影響を受けた値を算出可能とした点にある。なお、不確かさを組み込む前のシミュレーションプログラムは従来の決定論的な計算手法であり、これは真の値を算出する計算アプローチとみなすことができる。

例として温度を目標値とする弁開度制御を挙げる。真の温度に不確かさを加えて得られた温度計測値を用い、PI 制御器は弁開度指示値を出力する。この指示値に不確かさを加えて得られた開度が真の開度である。真の開度や真のポンプ回転数をもとに、原理的に真の流量が算出され、真の流量をもとに真の温度が算出される。そして、弁制御のために温度が再び計測される。この過程がシミュレーションでは 1 分刻みで繰り返される。なお、BEMS データとして収集される値は、その計測値に通信機器の不確かさを加えた値である。

実際の BEMS データと、シミュレーションにおいて最終的に出力する値とを区別するために、不確かさを考慮したシミュレーションによって算出された SCOP を監視 SCOP（Monitored SCOP）と名付けることとする。監視データは様々な不確かさの影響を含むため、BEMS データと本質的に比較可能であると考えられる。

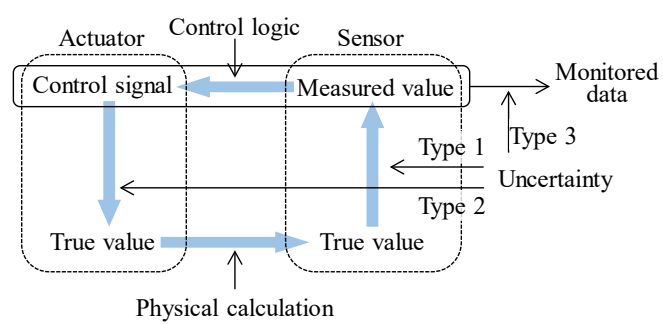


Fig. 4-2 Structure of uncertainties in the heat source system simulation

本検討において、不確かさは機器精度に基づく正規分布に従うものと仮定した。機器精度には、フルスケール値 (Full Scale, FS) と読み値 (Reading, RD) の 2 種類が存在する。FS は指定範囲に基づき不確かさのパラメータ (σ) が与えられる (Eq. (4-1))。RD では真値の絶対値に対して不確かさの値が与えられる (Eq. (4-2))。

$$x_{FS} = x_0 + rand \times \sigma \quad \text{Eq. (4-1)}$$

$$x_{RD} = x_0 \times (1 + rand \times \sigma) \quad \text{Eq. (4-2)}$$

where x_{FS} and x_{RD} are the values with the uncertainties, x_0 is the value without the uncertainty, $rand$ is a random number drawn from a standard normal distribution, and σ is the standard deviation of the uncertainty.

各機器で生じる不確かさをモデル化するためには、標準偏差 σ を決定する必要がある。本検討では、機器精度が 2σ となるよう、Table 4-1 に示すように具体的な値を与えた。

温度計測に関して、日本産業規格 (Japanese Industrial Standards, JIS) の「測温抵抗体」[22] において A 級の許容差 e は、Eq. (4-3) で表される。ここでは、測定温度範囲を 0°C から 100°C として $t=100$ とした。このとき、許容差 e は 0.35 となるため、これを 2σ として不確かさの標準偏差 σ を算出した。

$$e = \pm(0.15 + 0.002 \times |t|) \quad \text{Eq. (4-3)}$$

Where e is tolerant, t is temperature.

流量計測に関しては、文献[23]にて紹介のある流量計の精度を参照した。電力計測は JIS における精密電力量計の許容限度を参照した[24]。圧力計測は JIS における 1.0 級の許容誤差を参照した[25]。

なお、通信の不確かさとアクチュエータの不確かさは適切な文献が得られなかった。そのため、通信の不確かさパラメータは計測よりも小さいとして 0.1%，アクチュエータの不確かさは計測と同程度として 1%と仮定して与えた。なお、冷凍機 COP 計算といった計算モデルそのものにも誤差は生じうるが、収束条件を小さく設定したため問題ないとみなした。

対象システムのシミュレーションプログラムにおいて、不確かさはセンサ、アクチュエータ、通信機器でそれぞれ 130, 21, 118 か所に組み込まれた。組み込んだ不確かさの中には制御に用いられないセンサの不確かさなど、システム性能に影響を及ぼさないものも含まれる。

Table 4-1 Uncertainty modelling

Type	Target*	Unit	FS/RD**	Range	Accuracy	σ
1	Temp.	°C	FS	0–100	±0.35	0.175
	Flow	m ³ /min	RD	-	±2%	0.01
	Power	kW	RD	-	±1%	0.005
	Pressure	kPa	FS	0–500	±1%	2.5
2	INV	-	FS	0–1	±1%	0.005
	Valve	-	FS	0~1	±1%	0.005
3	Temp.	°C	FS	0–100	±0.1%	0.05
	Flow	m ³ /min	FS	0–20	±0.1%	0.01
	Power	kW	FS	0–500	±0.1%	0.25
	INV	-	FS	0–1	±0.1%	0.0005
	Valve	-	FS	0–1	±0.1%	0.0005
	Pressure	kPa	FS	0–500	±0.1%	0.25

* Temp.: Temperature, INV: Inverter frequency, Valve: Valve opening

** FS: full scale, RD: reading

4.4. 不確かさを考慮した性能分布の算出と不具合検知

4.4.1. モンテカルロ法

本検討では不確かさに基づく性能分布を算出するために、モンテカルロ法が用いられた。モンテカルロ法とは、ランダムサンプリングを反復するアルゴリズム全般を指し、複雑かつ非線形な空調システムにおける不確かさの影響を推定するためには適切であると考えられる。本検討では夏季代表週を対象期間とし、不確かさが組み込まれたシミュレーションを2,000回繰り返すことでSCOPの分布を算出した。このとき、不確かさは短い時刻では変化しないとの仮定のもと、毎時刻変化するのではなく、各試行においてEq. (4-1), Eq. (4-2), Table 4-1に従い値を更新することとした。なお、シミュレーションの入力値である熱負荷と下水温度の真値は常に同じ値を用いた。

4.4.2. 2007 年夏季代表週における性能分布

Fig. 4-3 に、2007 年の夏季代表週（7 月 28 日 22:00 から 8 月 4 日 21:59 まで）の負荷や下水温度を入力とし、モンテカルロ法により算出した SCOP の分布を示す。この分布の 90% 信頼区間は 4.69 から 5.20、平均値は 4.94 であり、BEMS データから得られた SCOP は 5.05 であった。なお、不確かさを考慮しない場合のシミュレーションによる SCOP は 4.96 であった。この 90% 信頼区間により、対象システムはこの時点で特に重大な不具合はみられないと判断することが可能となった。

なお、シミュレーションによる SCOP (4.96) と、BEMS データから得られる SCOP (5.05) を比較する場合、従来は両者の偏差の評価が不可能であった。本手法はこの BEMS データから得られる SCOP が、システムに重大な不具合がなくとも不確かさによって生じうるか否かを判断可能になったと考えられる。

Fig. 4-3 の分布に加えて、下記の異なる 5 つの分布も算出した。Fig. 4-4 は、Fig. 4-3 と同じ計算結果から算出した分布で、監視データ（全ての不確かさの結果として得られる計算結果）ではなく、シミュレーション中で算出されている真値から得られた SCOP が用いられている。この分布は左裾が長い分布であり、平均値も 4.95 と不確かさを考慮しない値 (4.96) よりもわずかではあるが低下していることから、不確かさによってシステム性能は低下する傾向にあることが示された。

Fig. 4-3 や Fig. 4-4 から分かるように、不確かさによって SCOP は向上する場合がある。供給熱量がセンサの不確かさによって小さく見積もられた場合に加え、もともとの制御が最適化されていないゆえに SCOP が向上したと考えられる。

なお、Fig. 4-4 はシミュレーション中で算出された真値を用いた分布であるため、全ての不確かさの結果である BEMS データとは本質的に比較すべきではない。同様の考え方で、Fig. 4-4 から Fig. 4-8 において BEMS データとの比較は行わないものとした。

Fig. 4-5 は、不確かさを考慮しない場合の計算結果に対し、SCOP の算出に用いる消費電力・二次冷水往還温度・二次冷水流量に単純に不確かさを加算した場合の SCOP 分布である。この分布は決定論的なシステムシミュレーションを 1 回実行し、その結果に不確かさに基づくノイズを加算するだけで得ることができるが、分布は Fig. 4-3 と大きく幅が異なるため、不具合検知には不適切であると考えられる。

Fig. 4-6 から Fig. 4-8 は不確かさをセンサ・アクチュエータ・通信機器のみにそれぞれ与えた場合の分布である。この中では、センサの不確かさのみを考慮した Fig. 4-6 が最も Fig. 4-3 に近かったため、センサにおける不確かさが熱源システムの性能に影響を及ぼすという観点から主要な不確かさであるといえる。なお、すべての不確かさを考慮した Fig. 4-3 の 90% 信頼区間は 4.69 から 5.20 であったのに対し、Fig. 4-6 の 90% 信頼区間は 4.71 から 5.20 であった。そのため、モデル化を単純にするという意味でセンサの不確かさのみをプログラムに組み込むだけであっても信頼区間の推定には十分実用的だと考えられる。

アクチュエータの不確かさに関しては、SCOP への影響が非常に小さかった (Fig. 4-7)。

弁開度の例を挙げると、指示値と実際の開度に不確かさによる乖離があったとしても、制御対象値（温度や流量）が目標値となるよう指示値が修正される。指示値が最大値または最小値となった場合のみ、目標値が達成できなくなるため、その影響によって SCOP のばらつきがわずかに生じたものと考えられる。

通信機器の不確かさに関しては、そもそもの不確かさの分散がセンサやアクチュエータに対して小さいため（Table 4-1 参照）、SCOP への影響も小さかったと考えられる（Fig. 4-8）。




Fig. 4-3 Monitored SCOP distribution in a week in 2007 derived from uncertainties.




Fig. 4-4 True SCOP distribution derived from uncertainties.




Fig. 4-5 SCOP distribution derived by adding uncertainties to the SCOP without uncertainties.




Fig. 4-6 SCOP distribution considering uncertainties in sensor measurements.




Fig. 4-7 SCOP distribution considering uncertainties in actuators.




Fig. 4-8 SCOP distribution considering uncertainties in communication equipment.

4.4.3. 2015 年夏季代表週における不具合検知

Fig. 4-3 からは、2007 年の夏季代表週においては重大な不具合はみられないことが示されたが、竣工後 8 年が経過した 2015 年の夏季代表週（8 月 1 日 22:00 から 8 月 8 日 21:59）において同様の手法で不具合検知を行った。

その結果、不確かさを考慮した SCOP の 90%信頼区間は 4.42 から 4.92 であったのに対し、BEMS データから得られた SCOP は 4.18 であった (Fig. 4-9)。そのため、対象システムには何らかの重大な不具合が生じていると判断できる。なお、不確かさを考慮しないシミュレーションによる SCOP は 4.65 であった。

2007 年と 2015 年では、同時期であるにも関わらず不確かさを考慮しない SCOP が 2015 年は 2007 年に対して 0.31 (6.3%) 低下した。両者はともに不具合を想定していないシミュレーションで算出された値であるため、負荷や下水温度といった境界条件によって SCOP が変化したものと考えられる。本手法は、このような境界条件による SCOP 変化にも対応した不具合検知が可能であると考えられる。

2007 年に対して、2015 年の夏季においてどのような不具合が生じているのか分析した事例を Fig. 4-10 に示す。冷水放熱用熱交換器 (CHEX) の出入口温度と流量から推定した熱交換面積を 2007 年と 2015 年とで比較した。熱交換面積そのものは変化しないが、熱交換器の汚れによる性能低下を表すパラメータとして、推定された熱交換面積を用いた。その結果、2015 年の推定熱交換面積は明らかに 2007 年の値よりも小さく、熱交換器の低能が低下していることが示された。なお、この不具合によっては、所定の二次冷水供給温度を達成するために一次冷水ポンプ動力が増加することが考えられる。

信頼区間と BEMS データから得られた SCOP の差を取ることで、不具合が全て取り除かれた場合の性能向上の幅を推定することが可能である。参考までに、Fig. 4-9 においては 0.24 (5.7%) から 0.74 (17.7%) の SCOP 向上が、不具合を取り除くことで得られると推定できる。

以上の検討より、提案手法がシステムにおける重大な不具合の有無を検知するのに有効であることが示された。しかし、本手法はどのような不具合が生じているかを直接診断できない。この不具合診断は次章以降で記述する。




Fig. 4-9 Fault detection by the monitored SCOP distribution in a representative week in 2015.

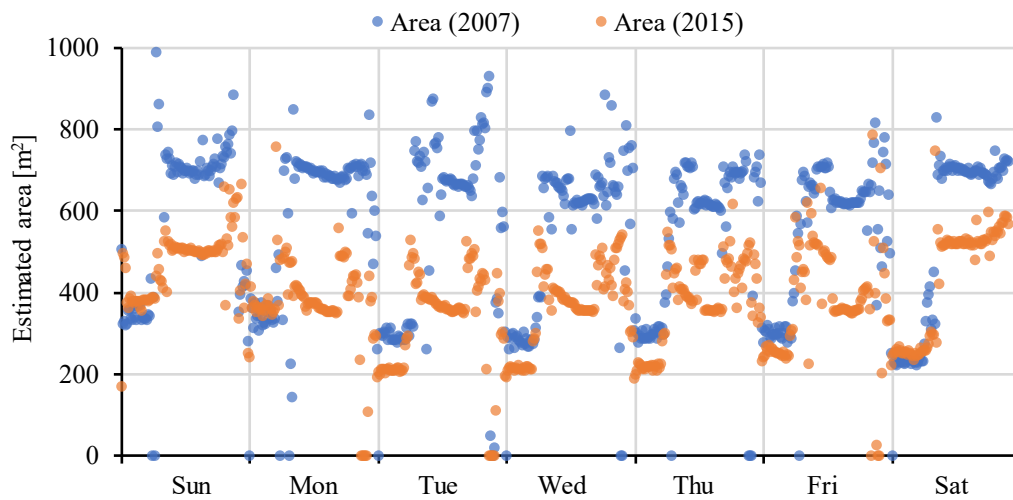


Fig. 4-10 Comparison of the monitored data between 2007 and 2015 (estimated heat exchange area at CHEX).

4.5. 計算回数に関する一考察

本検討では、性能分布を算出するために 2,000 回にわたる計算を行った。計算機の負荷をできる限り削減することは本手法の適用性にとって非常に重要であるため、サンプルサイズ（計算回数）に関する以下の考察を行った。

参考のために、2,000 の計算結果から 100 と 200 ずつ重複がないようにサンプルを抽出し、その 90%信頼区間（上位 95%点と上位 5%点）を算出した（Table 4-2, Table 4-3）。Table 4-2 から、各 100 サンプルにおける上位 95%点と上位 5%点の最大値と最小値の差がともに 0.09 であった。また、Table 4-3 から、各 200 サンプルにおける上位 95%点の最大値と最小値の差は 0.05、上位 5%点の最大値と最小値の差は 0.03 であった。2,000 サンプル時の上位 95%点（4.69）と上位 5%点（5.20）に対し、200 サンプルの誤差はそれぞれ 1.1%、0.6%であった。JIS で定められた遠心冷凍機の許容誤差が少なくとも約 5%であることを踏まえると[26], 200 サンプルの誤差は十分小さいとみなすことができる。そのため、2,000 サンプルはサンプルサイズとして分布の 90%信頼区間を推定するのに十分なサンプルサイズだと考えらえる。

なお、サンプルサイズを小さくするための手法として Latin hypercubic sampling が存在する[27]。しかし、本検討にて組み込まれた不確かさは合計 269 に上るため、依然として大きいサンプル数を要することが予想される。ただし、結果として得られる分布が滑らかになる可能性があるため、Latin hypercubic sampling を用いた分布の推定は今後の検討課題とする。

Table 4-2 Upper 95%, average, and upper 5% points in SCOP values in 100 samples

No.	Upper 95%	Average	Upper 5%
1	4.71	4.95	5.21
2	4.65	4.91	5.15
3	4.69	4.94	5.19
4	4.67	4.94	5.20
5	4.70	4.95	5.18
6	4.69	4.96	5.21
7	4.71	4.94	5.20
8	4.63	4.92	5.16
9	4.71	4.96	5.24
10	4.72	4.96	5.17
11	4.71	4.95	5.21
12	4.65	4.91	5.15
13	4.69	4.94	5.19
14	4.67	4.94	5.20
15	4.70	4.95	5.18
16	4.69	4.96	5.21
17	4.71	4.94	5.20
18	4.63	4.92	5.16
19	4.71	4.96	5.24
20	4.72	4.96	5.17
max	4.72	4.96	5.24
min	4.63	4.91	5.15

Table 4-3 Upper 95%, average, and upper 5% points in SCOP values in 200 samples

No.	Upper 95%	Average	Upper 5%
1	4.66	4.93	5.19
2	4.69	4.94	5.20
3	4.69	4.96	5.21
4	4.69	4.93	5.18
5	4.71	4.96	5.20
6	4.66	4.93	5.19
7	4.69	4.94	5.20
8	4.69	4.96	5.21
9	4.69	4.93	5.18
10	4.71	4.96	5.20
max	4.71	4.96	5.21
min	4.66	4.93	5.18

4.6. 今後の課題

本検討ではシミュレーションで SCOP 分布を算出するために不確かさを新たに定義したが、正規分布に従うことや分布のパラメータには仮定が含まれる。不確かさは直接観測できないため正しいモデル化は困難を伴うが、より適切なモデル化は今後の課題である。

今回は蓄熱槽を有する比較的複雑なシステムを対象としたが、より単純なシステムでは不確かさの影響は小さくなると考えられるため、信頼区間の幅も小さくなるものと想定される。これを確認するために、工場 B に本手法を適用した場合と今回の結果との比較も今後検討すべきであろう。また、二次側を含めた空調システム全体に不確かさを適用した際のシステム性能の分布を算出することも課題として挙げられる。

本章では制御系の不確かさがシステムへ及ぼす影響を検討したが、システムが有する不確かさとしては設計時に対する実際の配管内の圧力損失といった物理的な不確かさが挙げられる。制御系の不確かさと物理的な不確かさを比較または組み合わせることで、より一般的な検討が可能になると考えられる。

本章では熱源システムにおける不確かさをシミュレーションに組み込んだが、これを応用することでシステムが内包する不確かさの最適制御への影響も評価可能であろう。本章で算出した性能分布は、最適制御を行わなくとも不確かさによって性能が向上する場合があることを示唆している。しかし、最適制御は真値が最適となるよう設定値を探索するはずであるため、不確かさによる負の影響が相対的に大きくなることが想定される。そのため、最適制御と組み合わせることで新たな結果が得られる可能性がある。

4.7. 小括

本章では、熱源システムにおける不確かさを考慮したシステムレベルでの不具合検知に関する検討を行い、下記の知見を得た。

①不具合検知・診断スキームの提案

熱源システムにおける不具合検知・診断の枠組みとして、まず、不具合の有無そのものを検知し、次にどのような不具合が生じているかを診断し、診断された不具合の程度を同定することで不具合の修復効果を定量化することを提案した。本研究ではこのうち不具合の検知（第4章）と検知・診断（第5,6章）を検討対象とした。

②熱源システムにおける不確かさのモデル化

測定の不確かさ[10]に対し、熱源システムにおける不確かさをシミュレーションにおいて考慮するために機器精度に起因する避けられないノイズとして定義し、それをシステムシミュレーションに組み込んだ。

③不確かさを考慮した性能分布の算出

モンテカルロ法により不確かさによるノイズ値を更新しながらシミュレーションを2,000回実行することで、不確かさによる性能分布を算出した。

④性能分布を用いた不具合検知

性能分布から90%信頼区間を求め、これをBEMSデータと比較することで、重大な不具合がシステムに含まれているか否か判断する不具合検知を可能とした。BEMSデータ分析も同時に示すことで、本手法が有効であることを示した。

Acknowledgements

本章の検討は，JSPS Research Fellow, Grant number JP17J08140 と JSPS KAKENHI, Grant Number JP 18K13879 の支援を受けて遂行された。

参考文献

- [1] Venkatasubramanian Venkat, Rengaswamy Raghunathan, Yin Kewen, Kavuri Surya N. : A review of process fault detection and diagnosis: Part I: Quantitative model-based methods, Computers & Chemical Engineering, Vol. 27, No. 3, pp.293-311, 2003.
- [2] Venkatasubramanian Venkat, Rengaswamy Raghunathan, Kavuri Surya N. : A review of process fault detection and diagnosis: Part II: Qualitative models and search strategies, Computers & Chemical Engineering, Vol. 27, No. 3, pp.313-326, 2003.
- [3] Venkatasubramanian Venkat, Rengaswamy Raghunathan, Kavuri Surya N., Yin Kewen : A review of process fault detection and diagnosis: Part III: Process history based methods, Computers & Chemical Engineering, Vol. 27, No. 3, pp.327-346, 2003.
- [4] Bonvini Marco, Sohn Michael D., Granderson Jessica, Wetter Michael, Piette Mary Ann : Robust on-line fault detection diagnosis for HVAC components based on nonlinear state estimation techniques, Applied Energy, Vol. 124, pp.156-166, 2014.
- [5] Maletic Jonathan I., Marcus Andrian : Data Cleansing: Beyond Integrity Analysis., pp.200-209, 2000.
- [6] Chen Jiyi, Li Wenyuan, Lau Adriel, Cao Jiguo, Wang Ke : Automated load curve data cleansing in power systems, IEEE Transactions on Smart Grid, Vol. 1, No. 2, pp.213-221, 2010.
- [7] Li Ding, Li Donghui, Li Chengdong, Li Lin, Gao Long : A novel data-temporal attention network based strategy for fault diagnosis of chiller sensors, Energy and Buildings, Vol. 198, pp.377-394, 2019.
- [8] Li Guannan, Hu Yunpeng : Improved sensor fault detection, diagnosis and estimation for screw chillers using density-based clustering and principal component analysis, Energy and Buildings, Vol. 173, pp.502-515, 2018.
- [9] Wang Shengwei, Cui Jingtian : Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method, Applied Energy, Vol. 82, No. 3, pp.197-213, 2005.
- [10] JCGM JCGIM : Evaluation of measurement data—Guide to the expression of uncertainty in measurement, Int.Organ.Stand.Geneva ISBN, Vol. 50, pp.134, 2008.

- [11] International Organization for Standardization, 今井 秀 孝 : 計測における不確かさの表現のガイド : 統一される信頼性表現の国際ルール : ISO 国際文書 / ISO [編] ; 今井秀孝翻訳, 日本規格協会, 1996.
- [12] Wang Liping, Haves Philip : Monte Carlo analysis of the effect of uncertainties on model-based HVAC fault detection and diagnostics, HVAC&R Research, Vol. 20, No. 6, pp.616-627, 2014.
- [13] Domínguez-Muñoz Fernando, Anderson Brian, Cejudo-López José M., Carrillo-Andrés Antonio : Uncertainty in the thermal conductivity of insulation materials, Energy Buildings, Vol. 42, No. 11, pp.2159-2168, 2010.
- [14] Wang Liping, Mathew Paul, Pang Xiufeng : Uncertainties in energy consumption introduced by building operations and weather for a medium-size office building, Energy and Buildings, Vol. 53, pp.152-158, 2012.
- [15] Sun Yuming, Gu Li, Wu C. F. Jeff, Augenbroe Godfried : Exploring HVAC system sizing under uncertainty, Energy and Buildings, Vol. 81, pp.243-252, 2014.
- [16] Chung William, Hui Y. V., Lam Y. Miu : Benchmarking the energy efficiency of commercial buildings, Applied Energy, Vol. 83, No. 1, pp.1-14, 2006.
- [17] Wang Liping, Greenberg Steve, Fiegel John, Rubalcava Alma, Earni Shankar, Pang Xiufeng, Yin Rongxin, Woodworth Spencer, Hernandez-Maldonado Jorge : Monitoring-based HVAC commissioning of an existing office building for energy efficiency, Applied Energy, Vol. 102, pp.1382-1390, 2013.
- [18] Sun Biao, Luh Peter B., Jia Qing-Shan, O'Neill Zheng, Song Fangting : Building energy doctors: An SPC and Kalman filter-based method for system-level fault detection in HVAC systems, IEEE Transactions on Automation Science and Engineering, Vol. 11, No. 1, pp.215-229, 2013.
- [19] Wang Shengwei, Zhou Qiang, Xiao Fu : A system-level fault detection and diagnosis strategy for HVAC systems involving sensor faults, Energy and Buildings, Vol. 42, No. 4, pp.477-490, 2010.
- [20] Gao Dian-ce, Wang Shengwei, Shan Kui, Yan Chengchu : A system-level fault detection and diagnosis method for low delta-T syndrome in the complex HVAC systems, Applied Energy, Vol. 164, pp.1028-1038, 2016.
- [21] Zhang Rongpeng, Hong Tianzhen : Modeling of HVAC operational faults in building performance simulation, Applied Energy, Vol. 202, pp.178-188, 2017.
- [22] JIS : C 1604 測温抵抗体, 2013.

- [23] 一般社団法人建築設備総合協会：熱量・流量・温度計測マニュアル，2013.
- [24] JIS : C1216-1 電力量計（変成器付計器）－第1部：一般仕様，2009.
- [25] JIS : B7505-1 アネロイド型圧力計－第1部：ブルドン管圧力計，2017.
- [26] JIS : B8621 遠心冷凍機，2019.
- [27] McKay Michael D., Beckman Richard J., Conover William J. : Comparison of three methods for selecting values of input variables in the analysis of output from a computer code , Technometrics, Vol. 21, No. 2, pp.239-245, 1979.

本章に関連する発表論文

[国際会議・査読有・口頭]

1. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Yasuhiro KUWAHARA, Probabilistic Distribution of System Performance Output from BEMS by Heat Source System Simulation Incorporating Error Consideration, the 3rd Asia Conference of IBPSA-Asim 2016, ID 279, Jeju Korea, Nov. 2016
2. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Yasuhiro KUWAHARA, Fault detection in HVAC systems using a distribution considering uncertainties, REHVA 13th HVAC World Congress CLIMA 2019, Bucharest Romania, May 2019

第5章

不具合検知・診断—背景・目的と手法

5.1. 本章・次章の背景と目的

5.1.1. 既往の不具合検知・診断手法

1.1.や 1.2 では不具合の状況について、4.1 では不具合検知に注目して不具合検知・診断(FDD)に関する背景を述べた。本節ではどのようなFDD手法がこれまで検討されてきたか記述する。FDD手法は、4.1 で述べた通り定性的モデルベース手法、過去データベース手法、定量的モデルベース手法の3種類に分類される。

定性的モデルベース手法の代表例としてルールベース手法が挙げられる。ルールベース手法では、冷凍機の冷媒漏れといった不具合を対象とした検討や、専門家知識により構築されたAHUの評価手法が検討されている[1][2][3]。機器単位では運転条件に従ったルールを構築することが可能であり、AHUといった同一建物に数多く導入されるような機器にルールベース手法は適していると考えられる。その一方で、ルールベース手法はシステム全体で相互作用を受けるようなセンサや設定値不全といった不具合を検知・診断することが難しい。毎時刻変化する運転条件に対し、これらの不具合がシステム挙動をどのように変化させるか事前に記述することは詳細なシミュレーションなしでは不可能に近いためである。また、ルールベース手法では適切か否かのみを判断する場合がある。その場合は機器自体の運転が不適切であることは検知可能であっても、その原因が機器にあるのかシステムの他の部分にあるのか診断できない。加えて、システムごとに特定のルールを構築するためには多大な労力を要するという課題もある。

過去データベース手法の代表例として、異常検知が挙げられる。Yan et al.はAHUに関して事前に不具合データと不具合がないデータを用意することで異常検知を可能とし[4]、Beghi et al.は冷凍機に関して様々な運転モードでの異常検知を試みている[5]。このような異常検知は、検知開始時に異常がない前提で行われるため、そもそも異常が除去されていなければならない。そのため、本手法の適用は前提として詳細なデータ分析による手作業の不具合検知・診断が必要とされる。

定量的モデルベース手法としては、機械学習の利用が挙げられる。サポートベクターマシンやニューラルネットワーク、ランダムフォレストといった手法がすでに適用されている[6][7][8]。これらの手法の性能を決定づける要因は、機械学習手法そのものの性能に加え、利用するデータの質が挙げられる。データの質が悪いと高い性能の機械学習手法を用いたとしても、適切に診断することは難しいためである。

5.1.2. 本章・次章の目的

以上を踏まえ、空調システムの不具合検知・診断にはセンサを含む様々な不具合の診断が可能であり、手法構築のための人による労力が小さいことが重要であると考えられる。そこでルールを人が設定する必要のない、定量的モデルベース手法を用いることとした。その中で以下 3 点を目的・手法として検討を行った。

- ①質の高い不具合データを作成すること
- ②BEMS データを対象として、どの不具合が生じているか診断可能とすること
- ③診断結果を分析し、本手法の有効性を示すこと

5.1.3. 畳み込みニューラルネットワークを用いた FDD スキーム

本章で提案する手法は、FDD を分類問題として解くものである。定量的モデルベース手法として、畳み込みニューラルネットワーク（Convolutional Neural Networks, CNNs）を利用する。CNNs は画像認識に用いられる手法で、高い識別能力を有する。そこで、CNNs に不具合データの特徴を学習させ、BEMS データにどの種類の不具合の特徴が含まれるか診断させる（Fig. 5-1）。

CNNs に学習させる不具合データでは、不具合の特徴つまり不具合がある場合のシステム挙動が表現されている必要がある。シミュレーションを用いることで、設計時に想定された通りのシステム挙動に加え、様々な不具合条件を与えた結果としてのシステム挙動を算出することが可能である。本章では、BEMS データを学習データとして利用する手法は採らなかった。BEMS データの中にはどのような不具合が含まれているか不明であるため、データに対するラベリング自体が非常に困難であり質の高いデータベースの構築が現実的ではないためである。

シミュレーションで作成した不具合データにラベル（不具合番号）を付与したものを不具合データベースとし、これを CNNs に与えることで、どのような不具合が生じた場合にシステム挙動がどのような特徴を持つのが CNNs によって学習される。

そして、学習済み CNNs に BEMS データを与えることで、BEMS データがどの不具合データに近い診断される。

本手法は各不具合によるシステム挙動を算出可能なシミュレーションが必要であり、その構築に労力を要する。しかし、将来的にシミュレーションの構築自体は機器モデルの共有や Building Information Modelling（BIM）の発展といった形で労力が低減されることを本研究では想定している。その場合、データに現れる不具合の特徴の学習や、BEMS データの診断は CNNs によって自動で行われるため、必要な労力は診断したい不具合の条件をシミュレーションに与えるのみであると想定している。

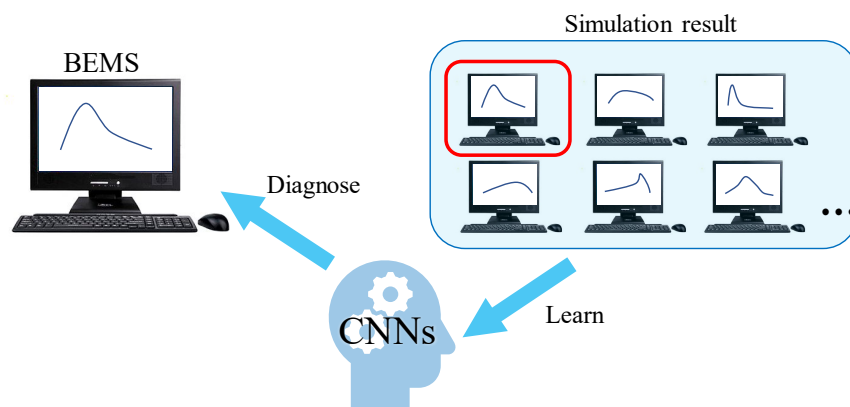


Fig. 5-1 Schematic of uncertainties in the heat source system.

5.1.4. 対象システム

本章では対象システムは, 事務所ビル A と工場 B の両方を対象システムとする。しかし, システムが異なると生じる不具合も変化する。そこで, 事務所 A にて 4 種類の不具合を想定した検討を行い, 工場 B ではより多くの不具合を対象とした検討を行った。

5.2. 不具合データベースの作成

5.2.1. 事務所 A

事務所 A では、不具合がない状態 (F0) に加え、2.1.のデータ分析をもとに 4 種類の不具合を想定した (Table 5-1)。設計仕様に基づき作成したシミュレーションに不具合の条件を与えることで不具合データを作成した。例えば、熱交換器の性能低下は熱交換効率を表すパラメータである熱交換面積を半減するといった形で不具合状態を表現した。

これらの計算結果にラベル (F0 から F4) を与えることで不具合データベースとした。F1 から F4 は、単体不具合のみならず複数組み合わせの場合も計算を行った。

Table 5-1 Assumed faults for Office A

Label	Fault target	Mainly related equipment	Conditions given to the simulation
F0	No faults	-	Performance and controls based on specifications.
F1	Performance of chillers	TR1, TR2, TR3, TR4	Due to condenser fouling, the pressure loss of condenser increases by 50% and efficiency deteriorates by 10%.
F2	Sewage pump set value	NP	The approach temperature is set to 1.0 °C from 2.0 °C.
F3	Heat exchanger efficiency	CHEX	Heat exchange area becomes 50%.
F4	Sensor offset for outlet temperature	Temperature sensor at outlet of HEX	The sensor measures the value lower than the true value by 1.0 °C.

不具合データは 2014 年の 7 月から 9 月の 122 日間の実負荷，下水温度を入力としてシミュレーションにより算出した。なお，2014 年の同時期の BEMS データを診断対象とした。

各計算結果の対象期間における供給熱量，消費電力量，SCOP，F0 に対する SCOP 変化率を Table 5-2 に示す。すべての場合において供給熱量はほぼ一致していたため，入力された負荷は不具合にかかわらず処理されたと考えられる。不具合は基本的に SCOP を低下させるものと想定していたが，F4 は与えた不具合によって SCOP が向上した。しかしながら F4 は供給される冷水温度を結果として上昇させ，二次側へ悪影響を及ぼす可能性があるため本検討では不具合とみなすこととした。

なお，各不具合データに関して日単位で F0 と変化があった日数を impacted days としてカウントした結果，全ての場合において計算日数である 122 であったため，各不具合は何らかの影響を毎日システム挙動に与えたと考えられる。

Table 5-2 Impact of faults on energy performance of Office A

Label	Supplied heat [GJ]	Power consumption [MWh]	SCOP	SCOP ratio [%]	Impacted days
F0	24338	1394	4.85	-	-
F1	24338	1535	4.40	-9.18	122
F2	24338	1441	4.69	-3.22	122
F3	24338	1436	4.71	-2.88	122
F4	24338	1360	4.97	2.48	122
F1+F2	24338	1579	4.28	-11.69	122
F1+F3	24338	1581	4.28	-11.81	122
F1+F4	24338	1499	4.51	-7.01	122
F2+F3	24338	1498	4.51	-6.95	122
F2+F4	24338	1399	4.83	-0.33	122
F3+F4	24338	1395	4.85	-0.08	122
F1+F2+F3	24338	1639	4.12	-14.95	122
F1+F2+F4	24338	1535	4.40	-9.19	122
F1+F3+F4	24338	1536	4.40	-9.25	122
F2+F3+F4	24338	1443	4.68	-3.42	122
F1+F2+F3+F4	24338	1581	4.27	-11.84	122

F1 から F4 がシステム挙動に与える影響の例として、F1 では冷凍機 (TR2) 消費電力、F2 では下水ポンプ (SP) 消費電力、F3 では冷水一次ポンプ (CP5)、F4 では行きヘッダ冷水温度について F0 との比較を Fig. 5-2 に示す。


F1 では冷凍機の COP が低下する条件を与えているため、当然の結果ではあるが消費電力が F0 に対して増加した (Fig. 5-2(a))。

F2 では下水ポンプ制御に関する設定値が変更された。下水ポンプは下水熱交換器 (SHEX) における冷却水出口温度をみながら回転数が制御される。このとき、熱交換器の仕様上では下水入口温度に対して冷却水出口温度は 2°C 高い値であるが、設定値不全として 1°C のみ高い温度となるように制御することとした。その結果、下水を最大限流しても冷却水を設定値まで冷却できず、消費電力が最大値となる挙動がみられた (Fig. 5-2(b))。


F3 では放熱用冷水熱交換器の交換面積を半減させ、熱交換効率を低下させた。その結果、F0 と同様の熱を供給するために一次側の流量を増加させる必要があり、冷水一次ポンプの消費電力が増加した (Fig. 5-2(c))。

F4 では冷水熱交換器 (CHEX) の二次側出口温度センサが真値に対して 1°C 低く計測するという不具合条件を与えた。冷水一次ポンプは熱交換器の二次側出口温度を参照して回転数が制御される。そのため、二次側出口温度の計測値が設定値である 7°C となるよう制御される。このとき、二次側出口温度の真値は設定値に対して 1°C 高い 8°C となるため、一次側の冷却に要する流量は低下する。そのため、ポンプの消費電力が減少し SCOP も向上した。しかし、実際に供給される温度である行きヘッダ温度は Fig. 5-2(d) に示されるように F0 に対して 1°C ほど上昇しており、これは結果として二次側に悪影響を及ぼしうる。なお、本検討では二次側の空調機や室内をモデル化していないためこの悪影響は定量化できない。そのため空気側も含めた不具合データ構築は今後の課題である。


以上の分析から、不具合データ設定時に想定された通りの計算結果が得られ、不具合によるシステム挙動の変化が適切に算出されたことが確認された。




(a) TR2 power



(b) NP power



(c) SCP4 power



(d) Supply chiller water temperature

Fig. 5-2 Influence of faults in system behavior (Office A)

5.2.2. 工場 B

工場 B では、不具合がない状態 (F0) に加え、文献[9] [10]も参考に機器構成や制御ロジックから想定しうる不具合を機器の性能低下、設定値不全、センサ誤差の観点から 39 種類 (F1–F39) を対象とした (Table 5-3)。これらの計算結果にラベル (F0–F39) を与えたものを不具合データベースとした。なお、今回入手できた BEMS データが 2013 年と 2014 年の 2 年間であったため、2013 年の BEMS データから作成した入力値 (熱負荷、外気温湿度) を用いて不具合データベースを作成し、2014 年の BEMS データを FDD の対象とした。

まず、それぞれのパターンで SCOP や F0 に対する変化率、F0 に対して挙動が変化した日数も算出した (Table 5-4)。

F0 から F39 について、年間の供給熱量はほぼ一致していたため入力された熱負荷は処理されたと考えられる。不具合によって SCOP が向上する場合があるが、設計仕様書通りの制御が最適ではない可能性が考えられる (F16, F20, F24 等)。また、冷水供給温度が変化して二次側へ影響を及ぼす可能性 (F4, F22 等) もある。不具合データを作成する前に制御を最適化しておくことが理想であるが、本報では制御仕様書に基づいた制御状態を不具合のない状態とみなすこととし、これらを不具合として検知・診断することを目的とする。

システム挙動に影響を及ぼした日数について、もともと 2013 年の BEMS データは欠損が 5 日分あったため、最大で 360 とした。想定した不具合条件をシミュレーションに与えたにも拘わらず影響がほぼ生じないものもあった (F8, F12, F29)。例えば F8 ではもともと冷凍機冷水ポンプ CP1 はほぼ回転数 50%以上で稼働していたため、下限値が従来よりも低く設定されてもシステム挙動に影響を与えなかったと考えられる。

不具合種類による傾向としては、冷水に関する不具合よりも、冷却水に関する不具合の方が SCOP への影響が大きかった。冷却水温度は冷凍機 COP に直接関係するためであるが、今回空気側はモデル化されていないため、冷水に関する不具合が冷却水に関する不具合に対して過小評価されている可能性がある。

Table 5-3 Assumed faults for Factory B

Label	Fault target	Mainly Related Equipment	Conditions given to the simulation
F0	No faults	-	Performance and controls based on specifications.
F1	TR	TR1, TR2	Pressure loss at condenser increases by 15% and COP
F2	CT	CT1, CT2	Heat exchange efficiency decreases by 10%.
F3	Piping	Piping for CP3~5	Pressure loss increases by 20%.
F4	TR operating number	TR1, TR2	Only TR1 is always operated.
F5			Both TR1 and TR2 are always operated.
F6	Lower limit of chilled water pump frequency	CP1	Lower limit which is originally 50% is set to 90%.
F7		CP2	
F8		CP1	Lower limit which is originally 50% is set to 10%.
F9		CP2	
F10	Lower limit of condenser water pump frequency	CWP1	Lower limit which is originally 45% is set to 90%.
F11		CWP2	
F12		CWP1	Lower limit which is originally 45% is set to 10%.
F13		CWP2	
F14	Set value for chilled water flow control	CP1	Set value increases by 0.1 m ³ /min.
F15		CP2	
F16		CP1	Set value decreases by 0.1 m ³ /min.
F17		CP2	
F18	Set value for condenser water flow control	CWP1	Set value increases by 0.1 m ³ /min.
F19		CWP2	
F20		CWP1	Set value decreases by 0.1 m ³ /min.
F21		CWP2	
F22	Set value for TR chilled water outlet temperature	TR1	Set value increases by 2.0 °C.
F23		TR2	
F24	Set value for CT condenser water outlet temperature	CT1, CT2	Set value increases by 1.0 °C.
F25			Set value decreases by 1.0 °C.
F26	Bypass valve control for condenser water	CWP1	Valve opening increases by 10%.
F27		CWP2	
F28		CWP1	Valve opening decreases by 10%.
F29		CWP2	
F30	Sensor offset for chilled water flow	CP1	The sensor measures the value higher by 0.1m ³ /min.
F31		CP2	
F32		CP1	The sensor measures the value lower by 0.1m ³ /min.
F33		CP2	
F34	Sensor offset for condenser water flow	CWP1	The sensor measures the value higher by 0.1m ³ /min.
F35		CWP2	
F36		CWP1	The sensor measures the value lower by 0.1m ³ /min.
F37		CWP2	
F38	Sensor offset for condenser water outlet temperature	CT1, CT2	The sensor measures the value higher by 1.0 °C.
F39			The sensor measures the value lower by 1.0 °C.

Table 5-4 Impact of faults on energy performance of Factory B

Label	Supplied heat [GJ]	Power consumption [MWh]	SCOP	SCOP ratio [%]	Impacted days
F0	26590	991	7.46	-	-
F1	26590	1079	6.84	-8.20	360
F2	26590	1000	7.39	-0.94	291
F3	26590	992	7.44	-0.18	359
F4	26590	943	7.83	5.03	94
F5	26590	1162	6.36	-14.73	315
F6	26590	1050	7.03	-5.69	360
F7	26590	1006	7.34	-1.54	90
F8	26590	991	7.46	0.00	8
F9	26590	989	7.47	0.14	33
F10	26590	1144	6.46	-13.39	360
F11	26590	1019	7.25	-2.82	89
F12	26590	991	7.46	0.00	3
F13	26590	990	7.46	0.09	34
F14	26590	995	7.42	-0.45	360
F15	26590	991	7.45	-0.06	87
F16	26590	988	7.48	0.28	360
F17	26590	990	7.46	0.03	81
F18	26590	1000	7.39	-0.90	359
F19	26590	1109	6.66	-10.70	360
F20	26590	983	7.52	0.82	359
F21	26590	988	7.47	0.24	88
F22	26590	934	7.91	6.08	360
F23	26590	991	7.46	-0.01	85
F24	26590	978	7.56	1.33	360
F25	26590	1122	6.58	-11.70	359
F26	26590	1020	7.24	-42.95	360
F27	26590	988	7.47	-43.02	360
F28	26590	991	7.45	-0.03	188
F29	26590	991	7.46	0.00	0
F30	26590	996	7.41	-0.58	360
F31	26590	998	7.40	-0.80	345
F32	26590	988	7.48	0.29	359
F33	26590	989	7.47	0.15	92
F34	26590	983	7.52	0.82	359
F35	26590	988	7.47	0.24	88
F36	26590	1000	7.39	-0.90	359
F37	26590	993	7.44	-0.24	87
F38	26590	1106	6.68	-10.45	359
F39	26590	970	7.62	2.14	357

5.3. データ前処理

5.3.1. 正規化

作成した不具合データベースを CNNs が効率よく学習可能するために、前処理を行った。具体的には、まず事務所 A の不具合データベースについて、流量や温度といった各項目の数値を Eq. (5-1)に従って 0 以上 1 以下の数値に変換した。この手法は正規化 (normalization) とも呼ばれる。この時の最大値・最小値は不具合データベース全体における値を指す。

$$\mathbf{x}_{normalized,A} = \frac{\mathbf{x} - \min(\mathbf{x})}{\max(\mathbf{x}) - \min(\mathbf{x})} \quad \text{Eq. (5-1)}$$

Where $\mathbf{x}_{normalized}$ is the normalized array, \mathbf{x} is the array before normalization, $\min(\mathbf{x})$ is the minimum value in \mathbf{x} , and $\max(\mathbf{x})$ is the maximum value in \mathbf{x} .

ただし、工場 B に関しては不具合種類が多く不具合の特徴をより直接表すための前処理が必要だと判断した。そこで学習効率を高めるために、F1-F39 において F0 との差を取りその値を正規化した (Eq. (5-2))。なお、工場 B における前処理の工夫が学習・診断結果に及ぼす影響については 6.2.3.にて考察を行った。

$$\mathbf{x}_{normalized,B} = \frac{\mathbf{x} - \mathbf{x}_0 - \min(\mathbf{x} - \mathbf{x}_0)}{\max(\mathbf{x} - \mathbf{x}_0) - \min(\mathbf{x} - \mathbf{x}_0)} \quad \text{Eq. (5-2)}$$

Where $\mathbf{x}_{normalized,B}$ is the normalized array, \mathbf{x} is the array before normalization (F1~F39), \mathbf{x}_0 is the array before normalization (F0), $\min(\mathbf{x} - \mathbf{x}_0)$ is the minimum value in $\mathbf{x} - \mathbf{x}_0$, and $\max(\mathbf{x} - \mathbf{x}_0)$ is the maximum value in $\mathbf{x} - \mathbf{x}_0$.

5.3.2. 画像化

正規化された値を用い、1 日分のデータを縦方向に時間、横方向に流量や温度といった項目とした 1 枚の画像に変換してこれを CNNs に与えることとした。代表日における各不具合データの画像を Fig. 5-3, Fig. 5-4 に示す。熱源システムは 1 日を最小の周期として運転されるため、不具合をシステムが有する場合は 1 日周期で何らかの影響が観察されると想定したためである。学習の効率化のために不具合データを 15 分平均データに変換したため、縦方向には 96 ピクセル、横方向には事務所 A が 120 ピクセル、工場 B は 48 ピクセルであった。カラー画像を機械学習・深層学習にて認識する際は、入力データは RGB の 3 種類の 2 次元データを有する多次元行列となるが、本検討では正規化にて得られたデータの 0 を白色、1 を黒色としてその間をグレースケールで表現することで 2 次元の白黒画像を用いることとした。

また、BEMS データも Eq. (5-1), Eq. (5-2)における最大値・最小値を用いて正規化し、同様に画像化したのちに学習済み CNN に与えた。そのため、本手法では 1 日に 1 回実行可能である。本検討で想定する不具合は、システムが停止して従来の BAS で警報として検出されるものではなく、エネルギー効率や二次側の制御に悪影響を及ぼし、修繕に投資判断を要するものである。そのため、1 日に 1 回とする FDD の頻度は適切であると考えられる。

画像化にあたり、横方向には機器毎に項目をグループ化して配置した。ランダムに配置するよりもシステム挙動の特徴を学習しやすくなると想定したためである。しかし、最適な項目の順番や配置に関しては検討の余地があるため今後の課題とする。




Fig. 5-3 Imaged faulty behavior data for Office A




Fig. 5-4 Imaged faulty behavior data for Factory B

5.4. 畳み込みニューラルネットワーク（CNNs）

5.4.1. 伝統的なニューラルネットワーク

Fig. 5-5 に表されるような構造の伝統的なニューラルネットワークは、1958 年に提案されたパーセプトロン[11]という概念を多層化したもので、多層パーセプトロンとも呼ばれる。各層は全結合しており、入力値に対して重み係数が与えられ、出力の際に活性化関数が与えられる。




Fig. 5-5 An example of multilayer perceptron

活性化関数はニューラルネットワークの出力に用いられる関数で、代表的なものにソフトマックス関数が挙げられる（Eq. (5-3)）。ソフトマックス関数は n 個の異なるクラスに対する確率分布を表現する関数であり、分類器に用いられる。また、他の活性化関数として正規化線形関数（rectified linear unit, ReLU）も推奨される場合がある[12] [13] [14]。

$$\text{softmax}(\mathbf{z})_i = \frac{\exp(z_i)}{\sum_j \exp(z_j)} \quad \text{Eq. (5-3)}$$

Where \mathbf{z} : Output of the linear layer. Unnormalized log probabilities.

5.4.2. 畳み込みニューラルネットワークの特徴

畳み込みニューラルネットワーク（Convolutional Neural Networks, CNNs）は主に画像認識に用いられる手法である。脳の視覚野をもとにモデル化がなされたネットワークの設計がもたになっており[15]，学習に誤差逆伝播法を用いたモデルが LeCun によって開発された[16]。CNNs の特徴は畳み込みとプーリングを行う点にある。

畳み込みとは，カーネルと呼ばれるパラメータの多次元配列を，入力であるデータの多次元配列に対して Fig. 5-6 のように行う処理を指す。カーネル内のパラメータは学習が進むにつれて変化する。伝統的なニューラルネットワークではドロップアウト等の工夫は存在するものの基本的に入力すべてと結合するパラメータが必要である。これに対して畳み込み処理は，画像の部分的なパターンを画像に対して小さいサイズのカーネルで学習可能であるため，学習が効率化される。




Fig. 5-6 An example of 2-D convolution, cited from [17].

プーリングとは、ある場所での値を周辺の値から要約して出力することを指す。周辺の最大値を出力とする最大プーリング（max pooling）の例を Fig. 5-7 に示す。Fig. 5-7 の上図における下側（0.1, 1., 0.2, 0.1）に対し、左右 1 項目との比較で最大値を上側（1., 1., 1., 0.2）へ出力する。下図では入力の数字が全て右に一つ移動して変化しているにもかかわらず、上側の出力は上図に対して半分しか変化しない。このように、最大プーリングは入力データの移動に対して柔軟性を与える効果がある。この特徴によって例えば、運転データにおいて負荷のピークが前後に異なり、不具合の特徴が別時刻に生じたとしても、不具合の特徴そのものを学習することが可能となると考えられる。

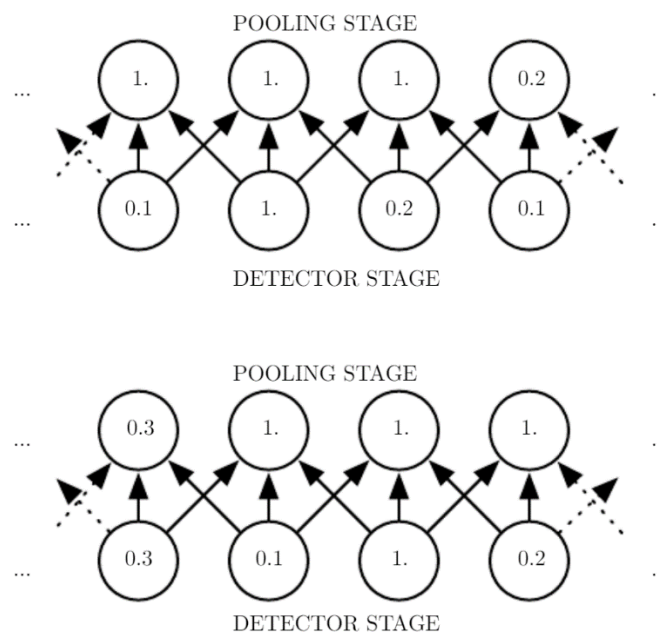


Fig. 5-7 Max pooling introduces invariance, cited from [17].

CNNs を含む機械学習では、出力の正解率が高くなるようにパラメータが訓練される。この時に用いられる代表的なパラメータ最適化手法は確率的勾配降下法（Stochastic Gradient Descent, SGD）である[18]。ニュートン法（3.3.3.参照）は勾配降下法の一例であり、確率的勾配降下法は訓練データから抽出された事例についてその勾配の平均が用いられる。本検討では確率的勾配降下法の発展形である Adam を採用した[19]。Adam はハイパーパラメータ（学習率）の設定に頑健であるとされる。

CNNs はその識別能力の高さがよく知られている。大規模な画像認識コンペティションである ILSVRC において、2016 年には CNNs に基づいた手法が識別誤り率 3% を下回った[20]。なお、ILSVRC では縦 224、横 224、RGB の入力画像に関して、訓練データ数 120 万、テストデータ数 15 万枚、1,000 クラスのカテゴリ識別が課題である。

5.4.3. 利用した CNNs の構造

本研究では空調システムの FDD に分類器としての CNNs を適用した。そのために、前節で示したように不具合データベースを前処理して画像化した。Fig. 5-3, Fig. 5-4 における各画像の違いはわずかであるため従来のニューラルネットワークではこれらの特徴を精度よく学習することは困難だと推定されるが、このデータベースを CNNs に適用することで、列方向に時間軸上の変化を、行方向にデータ間の関係性を抽出するパターン認識が可能であると想定した。

なお、CNNs は分類タスクにおける確率以外に物体検知 (object detection) も可能である。物体検知はピクセルごとに分類確率を出力して物体と背景の境界を検出することが可能である。しかし、BEMS データにおいて、不具合は様々な項目に影響を及ぼし、不具合が複数生じている場合は同じ項目に同時に影響を及ぼすことも考えられる。そのため今回システム挙動を画像化したものを踏まえると、画像ごとにどの不具合の特徴がみられるか確率を出力することで十分だと考えた。以上より、本検討における CNNs は分類タスクにおける確率を出力するものとした。

本研究で用いた CNN の構造を Fig. 5-8, Fig. 5-9 に示す。ReLU 関数を各畳み込み層と 1 つ目の全結合層の直後に配置し、2 つ目の全結合層の直後にはソフトマックス関数を配置した。この構造や畳み込みフィルタのサイズやチャンネル数、層の数といったパラメータは文献 [20] を参考にしながら試行錯誤により決定した。このように CNNs は複数の層で学習データの特徴を抽出するため、深層学習の一手法ともみなされる。




Fig. 5-8 Structure of the CNNs for Office A

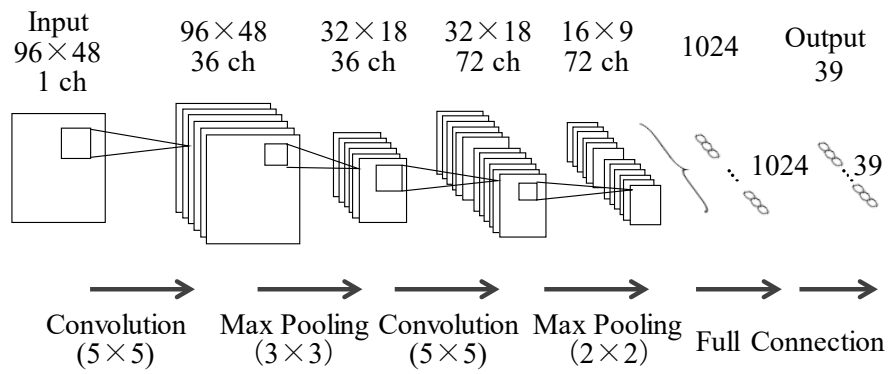


Fig. 5-9 Structure of the CNNs for Factory B

機械学習・深層学習には 3 種類のデータが用いられる。訓練データ、検証データ、テストデータである。訓練データと検証データは合わせて学習データとも呼ばれる。訓練データでネットワークを訓練する際、ネットワークのパフォーマンスを検証データにより評価する。訓練済みネットワークを実際に利用する際の性能を表すために、テストデータが用いられる。前述のコンペティションでは、テストデータにおける性能を競う。

本検討では学習データにシミュレーションで作成した不具合データベースを用い、テストデータに BEMS データを用いた。BEMS データは詳細な分析によりどの不具合が生じているか把握がなされているが、それでも見つけられていない不具合は潜んでいると考えられる。そのため、今回はテストデータにおいて正解率を算出するのではなく、診断結果と BEMS データ分析とを比較することで、診断の妥当性や BEMS データへの本手法の適用性を考察することとした。

事務所 A では、各不具合データ（学習データ）122 日分のうち、20 日分を検証データとしてランダムに抽出し、残りを訓練データとして不具合データの学習を行った。30 の CNNs に対してこの訓練を行い、BEMS の診断はこの 30 の学習済み CNNs の出力を平均することでより高い性能を目指した。

工場 B でも同様に 30 の CNNs に学習を行わせたが、不具合の影響がみられた日数が不具合種類によって異なっていた。そこで、影響があまり見られなかった不具合種類（F8, F9, F12, F13, F29）を取り除き、それ以外で最も小さい値である 81 日分を各不具合データから抽出して学習データとした。なお、その中で 13 日分をランダムに抽出してこれを検証データ、残りを訓練データとした。

本検討では、CNNs のモデル化に深層学習フレームワークである TensorFlow を利用した [21]。検討に用いた際の Tensorflow のバージョンは 1.8.0 であった。

5.5. 小括

本章では, CNNs を用いた FDD を行うために, 必要な不具合データベースの作成と CNNs の特徴について記述した。

①不具合データベースの作成

第 3 章で構築した詳細な熱源システムシミュレーションプログラムを用い, 不具合の条件をプログラムに与えた。不具合を有するシステム挙動が算出可能であることを計算結果の分析から示した。

②不具合データの画像化

不具合データベースを CNNs が学習可能な形をするために, 1 日分のシステム挙動を 1 枚のグレースケールの画像へ変換した。

③CNNs の FDD 応用への適用性

CNNs の特徴を整理することで, CNNs が分類器として空調システムの FDD に適していることを示した。具体的には, CNNs は画像内の時刻方向や項目間の特徴を, カーネル内のパラメータによって学習することが可能である。CNNs 自体の性能の高さも踏まえ, 不具合によるシステム挙動の特徴を学習することが可能であると考えられる。

Acknowledgements

本章の検討は、東京電力ホールディングス株式会社 (Tokyo Electric Power Company Holdings, Inc.), JSPS Research Fellow, Grant number JP17J08140 と JSPS KAKENHI, Grant Number JP18K13879 の支援を受けて遂行された。

参考文献

- [1] Rossi Todd M., Braun James E. : A statistical, rule-based fault detection and diagnostic method for vapor compression air conditioners, HVAC&R Research, Vol. 3, No. 1, pp.19-37, 1997.
- [2] Schein Jeffrey, Bushby Steven T., Castro Natascha S., House John M. : A rule-based fault detection method for air handling units, Energy and Buildings, Vol. 38, No. 12, pp.1485-1492, 2006.
- [3] Schein Jeffrey, Bushby Steven T. : A Hierarchical Rule-Based Fault Detection and Diagnostic Method for HVAC Systems, HVAC&R Research, Vol. 12, No. 1, pp.111-125, 2006.
- [4] Yan Rui, Ma Zhenjun, Zhao Yang, Kokogiannakis Georgios : A decision tree based data-driven diagnostic strategy for air handling units, Energy and Buildings, Vol. 133, pp.37-45, 2016.
- [5] Beghi A., Brignoli R., Cecchinato L., Menegazzo G., Rampazzo M., Simmini F. : Data-driven Fault Detection and Diagnosis for HVAC water chillers, Control Engineering Practice, Vol. 53, pp.79-91, 2016.
- [6] Liang J., Du R. : Model-based Fault Detection and Diagnosis of HVAC systems using Support Vector Machine method, International Journal of Refrigeration, Vol. 30, No. 6, pp.1104-1114, 2007.
- [7] Du Zhimin, Fan Bo, Jin Xinqiao, Chi Jinlei : Fault detection and diagnosis for buildings and HVAC systems using combined neural networks and subtractive clustering analysis, Building and Environment, Vol. 73, pp.1-11, 2014.
- [8] Frank Stephen, Heaney Michael, Jin Xin, Robertson Joseph, Cheung Howard, Elmore Ryan, Henze Gregor : Hybrid model-based and data-driven fault detection and diagnostics for commercial buildings, Proceedings of the 2016 ACEEE Summer Study on Energy Efficiency in Building, 2016.
- [9] 宋永学, 赤司泰義 : 空調システムの不具合検知・診断ツール開発に関する基礎研究, 日本建築学会環境系論文集, 第 71 巻, 第 607 号, pp.71-78, 2006.
- [10] 田井佑典, 住吉大輔, 赤司泰義, 桑原康浩 : 2 種類のシミュレーションモデルを用いた熱源システムのセンサ・機器不具合検知手法, pp.229-232, 2015.

- [11] Rosenblatt Frank : The perceptron: a probabilistic model for information storage and organization in the brain, *Psychological Review*, Vol. 65, No. 6, pp.386, 1958.
- [12] Jarrett Kevin, Kavukcuoglu Koray, Ranzato Marc'Aurelio, LeCun Yann : What is the best multi-stage architecture for object recognition?, *IEEE 12th International Conference on Computer Vision (ICCV)*, pp.2146-2153, 2009.
- [13] Nair Vinod, Hinton Geoffrey E. : Rectified linear units improve restricted boltzmann machines, pp.807-814, *Proceedings of the 27 th International Conference on Machine Learning*, Haifa, Israel, 2010.
- [14] Glorot Xavier, Bordes Antoine, Bengio Yoshua : Deep sparse rectifier neural networks, *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pp.315-323, 2011.
- [15] Fukushima Kunihiro : Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, Vol. 36, No. 4, pp.193-202, 1980.
- [16] LeCun Yann, Boser Bernhard, Denker John S., Henderson Donnie, Howard Richard E., Hubbard Wayne, Jackel Lawrence D. : Backpropagation applied to handwritten zip code recognition, *Neural Computation*, Vol. 1, No. 4, pp.541-551, 1989.
- [17] Goodfellow Ian, Bengio Yoshua, Courville Aaron : Deep learning, *The MIT Press*, 2016.
- [18] Bottou Léon : Large-scale machine learning with stochastic gradient descent, *Proceedings of COMPSTAT'2010*, pp.177-186, 2010.
- [19] Kingma Diederik P., Ba Jimmy : Adam: A method for stochastic optimization, *arXiv preprint arXiv:1412.6980*, 2014.
- [20] Simonyan Karen, Zisserman Andrew : Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.
- [21] Abadi Martín, Barham Paul, Chen Jianmin, Chen Zhifeng, Davis Andy, Dean Jeffrey, Devin Matthieu, Ghemawat Sanjay, Irving Geoffrey, Isard Michael : Tensorflow: A system for large-scale machine learning , *12th USENIX Symposium on Operating Systems Design and Implementation*, pp.265-283, 2016.

本章に関連する発表論文（次章と共通）

[学術雑誌・査読有]

1. 宮田翔平, 赤司泰義, 林鐘衍, 呉楊駿, 田中勝彦, 田中覚, 桑原康浩, 機械学習を用いた空調熱源システムの不具合検知・診断 第 1 報—シミュレーションによる不具合データベース作成と畳み込みニューラルネットワークによる不具合検知・診断, 空気調和・衛生工学会論文集, 第 43 巻, 第 257 号, pp.11-20, 2018 年
2. 宮田翔平, 赤司泰義, 林鐘衍, 本村彬, 田中勝彦, 田中覚, 桑原康浩, 機械学習を用いた空調熱源システムの不具合検知・診断 第 2 報—診断性能向上のための不具合データの前処理と BEMS データへの適用, 空気調和・衛生工学会論文集, 第 43 巻, 第 261 号, pp.1-9, 2018 年
3. Shohei MIYATA, Jongyeon LIM, Yasunori AKASHI, Yasuhiro KUWAHARA, Katsuhiko TANAKA Fault detection and diagnosis for heat source system using convolutional neural network with imaged faulty behavior data, Science and Technology for the Built Environment, Published online: 03 Sep 2019

[国際会議・査読有・口頭]

4. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Katsuhiko TANAKA, Satoru TANAKA, Yasuhiro KUWAHARA, Model-Based Fault Detection and Diagnosis Using Convolutional Neural Networks in Heat Source System with Water Thermal Storage Tanks, the 4th Asia Conference of IBPSA – ASim 2018, ID 523, Hong Kong, Dec. 2018
5. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Yasuhiro KUWAHARA, Katsuhiko TANAKA, Model-based Fault Detection and Diagnosis for HVAC Systems Using Convolutional Neural Network, 16th IBPSA International Conference Building Simulation – BS 2019, Rome Italy, August 2019

第6章

不具合検知・診断—結果と考察

6.1. CNNs の学習結果

6.1.1. 事務所 A

400 エポックにわたる学習の結果, 30 の CNNs の検証データに対する平均精度 (正解率) は 98.4%であった (Fig. 6-1)。訓練データと検証データの精度が乖離する過学習もみられないため, CNNs は不具合データの特徴を十分に学習したと判断した。

なお, 計算にはメモリ 64GB, プロセッサに 8 つのコア (Intel® Core™ i7-7820X CPU @ 3.60GHz), GPU に NVIDIA GeForce GTX 1080Ti を有する計算機を用いた。参考までに, 30 の CNNs すべてを学習させるのに要した時間は 5 時間 24 分であった。




Fig. 6-1 Learning curves of CNNs for Office A.

6.1.2. 工場 B

400 エポックにわたる学習の結果, 30 の CNNs の検証データに対する平均精度 (正解率) は 98.3%であった (Fig. 6-2)。事務所 A と同様に訓練データと検証データの精度が乖離する過学習もみられないため, CNNs は不具合データの特徴を十分に学習したと判断した。参考までに, 前節と同じ計算機を用い, 30 の CNNs すべてを学習させるのに要した時間は 10 時間 4 分であった。




Fig. 6-2 Learning curves of CNNs for Factory B.

6.1.3. 不具合の程度と診断結果に関する一考察

CNNs はシミュレーションで用意した不具合の特徴を十分学習可能であることがわかった。この検証に用いたシステム挙動データは、負荷等の入力条件は違えども不具合の程度（不具合条件としてシミュレーションに設定したパラメータ）は同様であった。しかし、実際の BEMS データは様々な不具合が様々な程度で生じた結果としてのシステム挙動を表していると想定できる。そこで、本節では学習済みネットワークが程度の異なる不具合をどのように診断するか分析・考察した。なお、本節での検討は事務所 A を対象とした。

CNNs の学習に用いた不具合データベースにおける各不具合の程度は、Table 6-1 に赤字で示した通りであった。この程度を 100% として、20% から 180% まで 20% 刻みの不具合条件を与えたシミュレーションを行い、新たに不具合データを作成した（Table 6-2）。例えば、F4 は温度センサが真値よりも 1.0°C 低く計測する不具合であるが、20% では 0.2°C、180% では 1.8°C 真値よりも低く計測するものとした。

なお、学習に用いた不具合データベースは 2014 年の負荷等を入力値としたが、新たな不具合データはテストデータの意味で 2015 年の負荷等を入力値とした。

Table 6-1 Assumed faults for Office A

Label	Fault target	Mainly related equipment	Conditions given to the simulation
F0	No faults	-	Performance and controls based on specifications.
F1	Performance of chillers	TR1, TR2, TR3, TR4	Due to condenser fouling, the pressure loss of condenser increases by 50% and efficiency deteriorates by 10%.
F2	Sewage pump set value	NP	The approach temperature is set to 1.0 °C from 2.0 °C.
F3	Heat exchanger efficiency	CHEX	Heat exchange area becomes 50%.
F4	Sensor offset for outlet temperature	Temperature sensor at outlet of HEX	The sensor measures the value lower than the true value by 1.0 °C.

Table 6-2 Fault conditions for several severities.

Label	Severity [%]	Fault target	Fault detail and severity	
F1	20%	Performance of chillers	Due to condenser fouling, the pressure loss of condenser increases by $x\%$ and efficiency deteriorates by $y\%$	10%, 2%
	40%			20%, 4%
	60%			30%, 6%
	80%			40%, 8%
	100%			50%, 10%
	120%			60%, 12%
	140%			70%, 14%
	160%			80%, 16%
	180%			90%, 18%
F2	20%	Sewage pump set value	The approach temperature is set to $x^{\circ}\text{C}$ from 2.0 $^{\circ}\text{C}$	1.8 $^{\circ}\text{C}$
	40%			1.6 $^{\circ}\text{C}$
	60%			1.4 $^{\circ}\text{C}$
	80%			1.2 $^{\circ}\text{C}$
	100%			1.0 $^{\circ}\text{C}$
	120%			0.8 $^{\circ}\text{C}$
	140%			0.6 $^{\circ}\text{C}$
	160%			0.4 $^{\circ}\text{C}$
	180%			0.2 $^{\circ}\text{C}$
F3	20%	Heat exchanger efficiency	Heat exchange area becomes $x\%$	10%
	40%			20%
	60%			30%
	80%			40%
	100%			50%
	120%			60%
	140%			70%
	160%			80%
	180%			90%
F4	20%	Sensor offset for outlet temperature	The sensor measures the value lower than the true value by $x^{\circ}\text{C}$	0.2 $^{\circ}\text{C}$
	40%			0.4 $^{\circ}\text{C}$
	60%			0.6 $^{\circ}\text{C}$
	80%			0.8 $^{\circ}\text{C}$
	100%			1.0 $^{\circ}\text{C}$
	120%			1.2 $^{\circ}\text{C}$
	140%			1.4 $^{\circ}\text{C}$
	160%			1.6 $^{\circ}\text{C}$
	180%			1.8 $^{\circ}\text{C}$

Fig. 6-3 は、F0 に対する各不具合による SCOP の変化率を示した図である。不具合の程度は 20% から 180% まで線形に変化させたが、SCOP は直線的に変化しなかった。熱源システムは機器特性や制御が非線形であるため、不具合の程度がシステム挙動に非線形に影響を及ぼしたと考えられる。




Fig. 6-3 SCOP influenced by faults with several severities.

6.1.1 にて学習された CNNs を用い、Table 6-2 の様々な程度の不具合を診断した (Fig. 6-4, Fig. 6-5)。なお、各程度における診断確率は、対象 122 日間における平均値である。

まず、単一不具合に関して、不具合の程度が 100% に近づくにつれ、診断確率も 100% に近くなった (Fig. 6-4 (a) から (d))。100% を超えた場合の診断確率はほぼ 100% のままであった。

そのため、CNNs が学習した不具合の特徴に対して程度の小さい不具合は、システム挙動への影響も小さいため、診断確率が低下することが明らかになった。その一方で、この CNNs は F0 (不具合がない場合) も学習しているため、F0 の診断確率が増加することとなったと考えられる。

ただし、F3 のみにおいて程度が 100% を超えたときに異なる不具合 (F1) の診断確率が生じた。F3 によって一次側の冷水流量が増加し、冷水一次ポンプ動力の増加や冷凍機の効率低下が引き起こされたためと考えられる。しかし、100% 付近ではこのような誤診はほぼ見られなかった。

不具合が複数生じていた場合の診断確率について分析するために、2 種類の不具合を同時に与え、片方を程度 20% から 180% まで変動させた不具合データの診断も行った (Fig. 6-4 (e) から Fig. 6-5 全て)。基本的に、100% 以上の程度の場合は両方の診断確率が約 50% となり、程度が 100% 未満の場合はその診断確率が低下するとともにもう片方の診断確率が増加した。例えば、Fig. 6-4 (e) では F1 と F2 の不具合を与え、F1 は不具合の程度を 20% から 180% まで変動させる一方で F2 は不具合の程度を 100% で固定させた。その結果、F1 の程度が 100% 未満の時は程度が増加するにつれて診断確率が増加し、F1 の程度が 100% 以上では約 50%

となった。残りの診断確率はほぼ F2 であり、他の診断確率は非常に小さかった。

これによって、不具合が複数生じている場合、程度が不具合データベースにて想定したものよりも小さい場合は診断確率が小さくなるが、程度が想定よりも大きくても別の不具合の診断確率を低下させることはないことが明らかになった。また、ここでも F3 の診断結果は単一不具合の場合と同様であった (Fig. 6-5 (d), (g))。

基本的に 2 つの不具合が同時に生じている場合は程度が 100%を超えると両方の診断確率はほぼ 50%であったが、F3 と F4 の組み合わせはこの限りではなかった (Fig. 6-5 (g), (h))。F3 と F4 が同時に生じた場合、F3 の程度が大きくなるほど F4 の診断確率が低下し、F3 の程度が 180%の時は F4 の診断確率がほぼ 0 になった。この逆も同様であった。F3 は放熱用冷水熱交換器の性能低下であるため、冷水一次流量が増加する影響を与える。その一方で F4 は同じ熱交換器の冷水二次出口温度センサの誤差であり、真値よりも値が低く計測されるため、冷水一次流量が減少する影響を与える。つまり、F3 と F4 はシステム挙動に対して逆に作用するため、片方の程度が強くなるともう片方の影響を打ち消してしまう。そのためにこのような診断結果になったと考えられる。

以上より、例外はあるが診断確率はその不具合の有無を表すとともに、相対的な程度を表現することが明らかとなった。ただし、診断確率の値をそのまま不具合の程度に変換できるものでないため、診断された不具合の程度を同定するプロセスが必要と考えられる。

また、不具合データベース作成時に想定した程度よりも診断対象の程度が大きい場合でも、診断結果は変化しない事例がみられたため、不具合データベース作成の際に入力値となる程度は診断結果にとって重要であると考えられる。例えば、感度よく診断したい不具合は程度を小さめに設定することで診断確率を上げることができるといった工夫が考えられる。

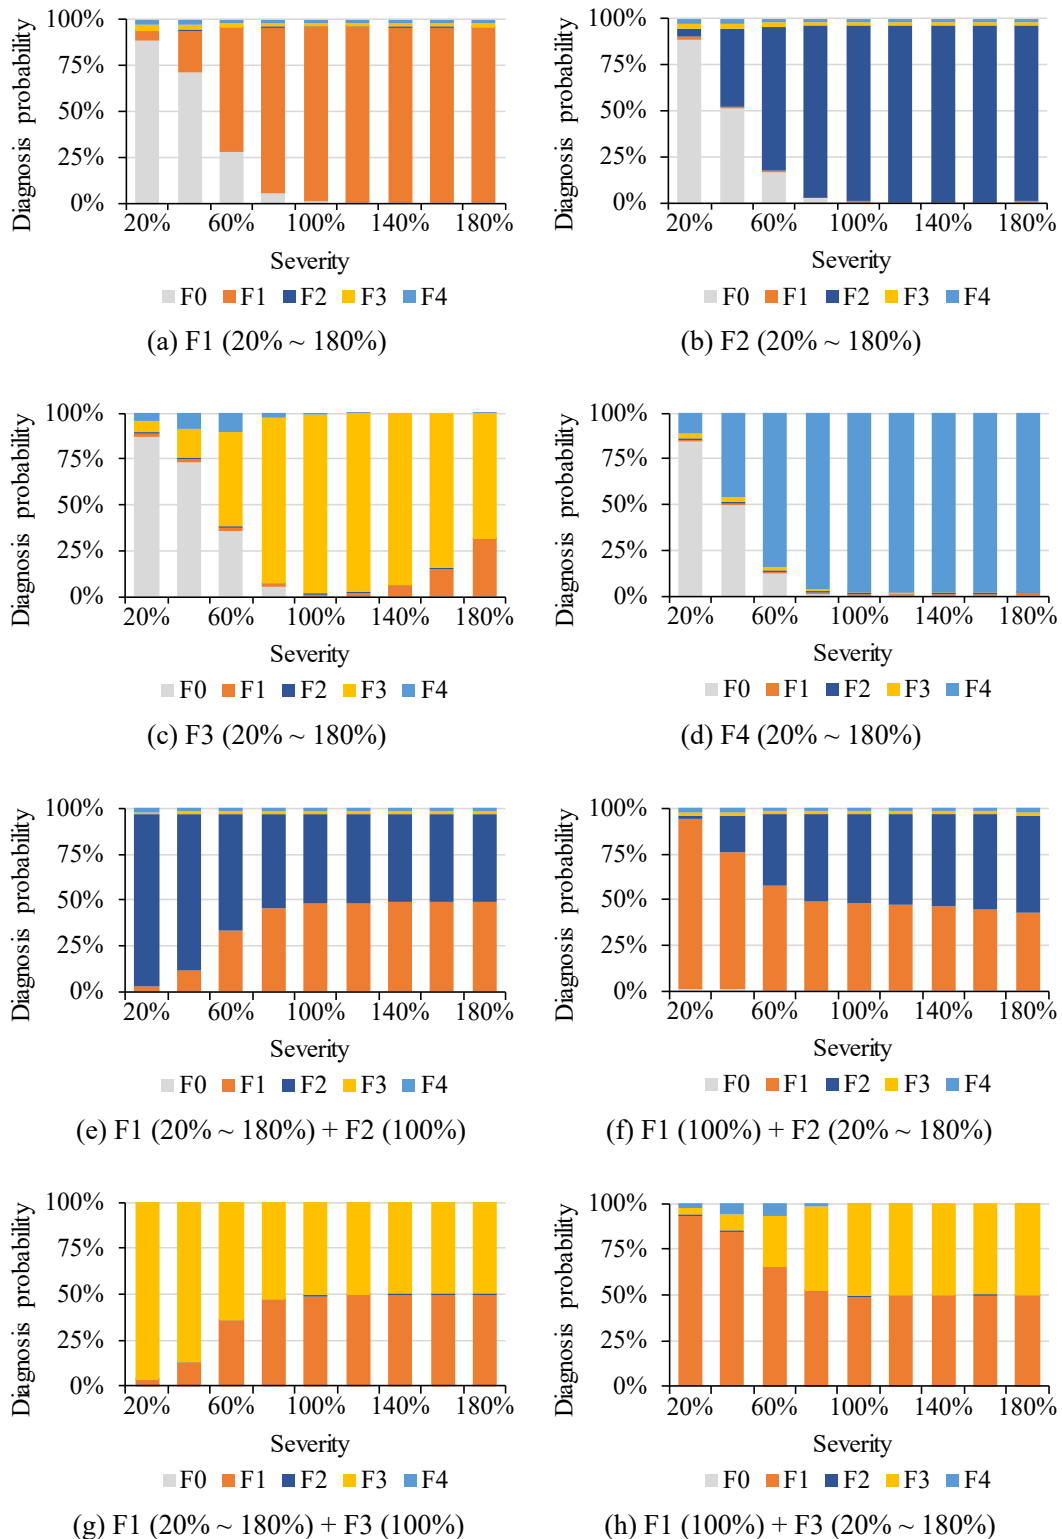


Fig. 6-4 Impact of faults with different severities on diagnosis probabilities (1).

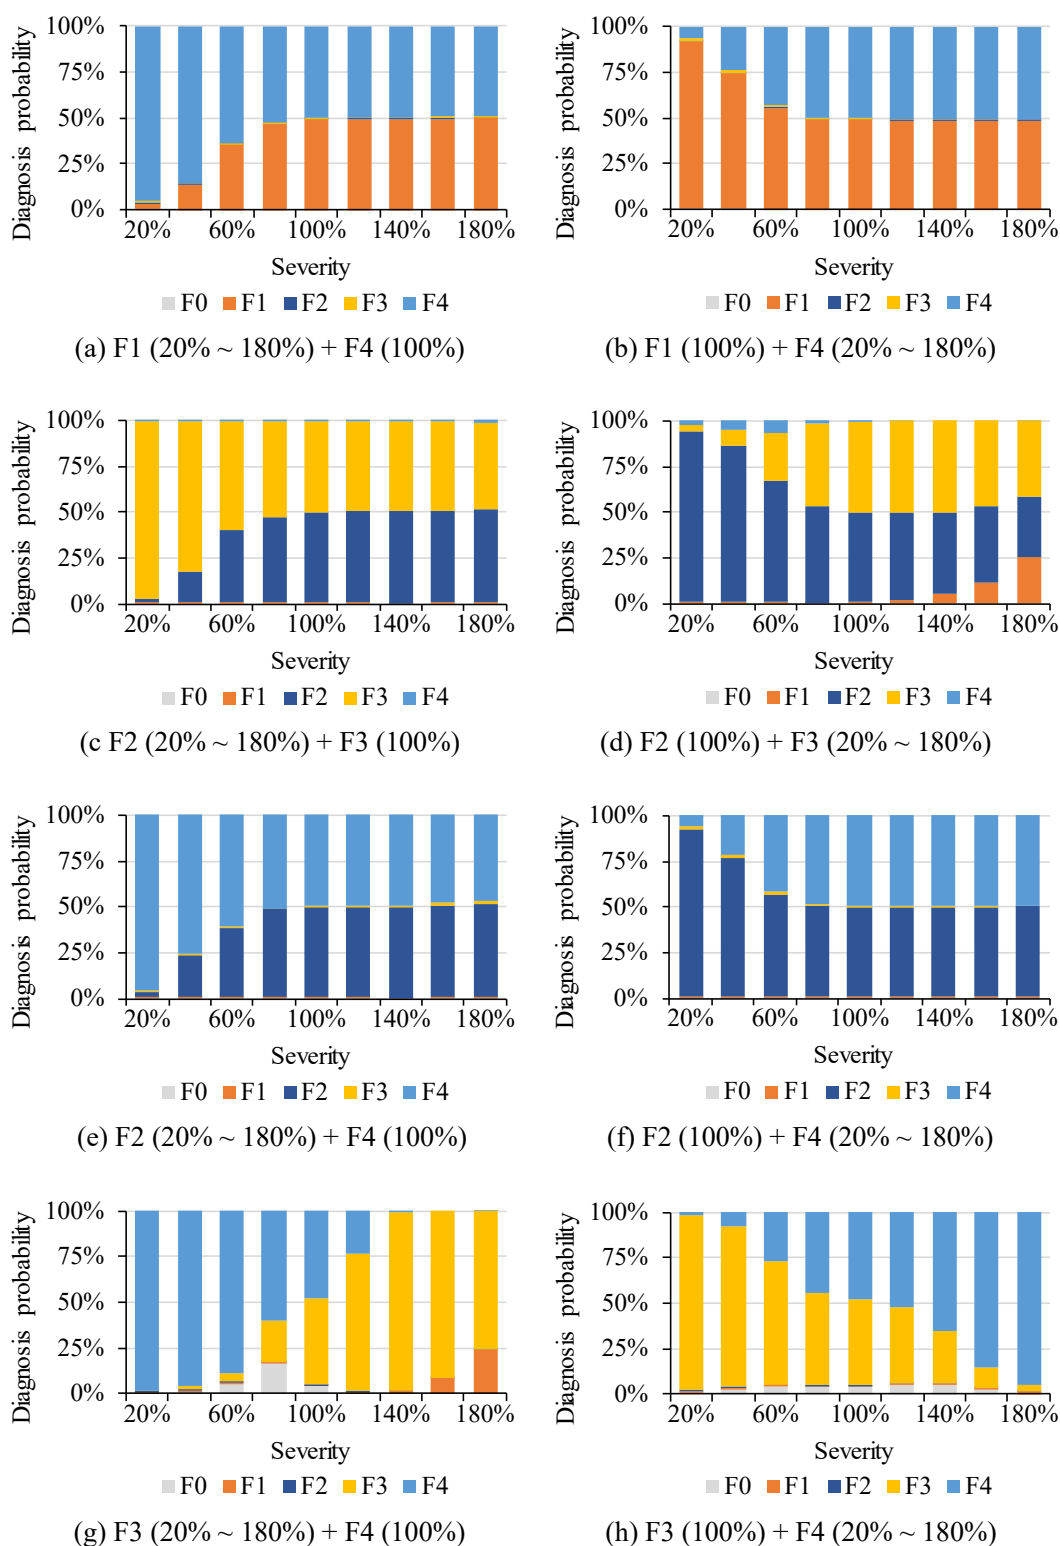


Fig. 6-5 Impact of faults with different severities on diagnosis probabilities (2).

6.2. BEMS データ診断結果

6.2.1. 事務所 A

6.1.1 にて訓練された CNNs を用いて 2015 年の BEMS データを診断した (Fig. 6-6, Table 6-3)。事務所 A では複数不具合の組み合わせも学習対象としたが、これらが診断された場合は均等に各不具合へと診断確率を割り振った。結果としては、F3 が最も確率高く診断され、F1 と F4 は期間を通して低い確率であり、F2 はある時期にのみ診断確率が生じた。

診断は一日に一回行われるため、毎日異なる診断確率が得られる。なお、対象期間において不具合が修繕された記録はなかった。そのため、診断確率が毎日変化する原因は運転状況が変化することで不具合の特徴の現れ方も変化したことだと考えられる。

6.1.3.における考察を踏まえ、各不具合における診断確率、データベース作成時に想定した程度、BEMS データから推定される程度を Fig. 6-7, Fig. 6-8 に示す。F1 から F4 を通し、不具合がない場合のレベルに対して想定した不具合の程度の方に BEMS データのレベルが推移すると、診断確率が大きくなる傾向が得られた。F1 では冷凍機 COP の機器仕様に対する変化率を BEMS データから算出し、これを BEMS データから推定した F1 の程度とした。性能低下があまりみられない 6 月では診断確率も小さいが、性能低下率が大きくなる 8 月ころは診断確率が増加した (Fig. 6-7(a))。F2 では不具合の程度指標として算出したアプローチ温度 (下水温度と冷却水出口温度の差) が 2.0°C を下回ると診断確率が生じた (Fig. 6-7(b))。F3 は最も診断確率が高かった。想定した不具合の程度と BEMS データから推定された実際の程度が非常に近かったためと考えられる (Fig. 6-8(a))。F4 では BEMS データとして熱交換器二次送水温度と行きヘッダ温度の両方が測定されていたため、行きヘッダ温度を正と仮定して本不具合の実際の程度を推定した。本来この二つのセンサは同じ値を示すべきであるが、対象期間を通して 0.1°C ほどの差が生じていた。不具合データベース作成時の F4 の想定は 1°C の誤差であったため、診断確率は低い値であった (Fig. 6-8(b))。




Fig. 6-6 Diagnosis probability for Office A.

Table 6-3 Average diagnosis probabilities for Office A

	F0	F1	F2	F3	F4
Average diagnosis probability	22.4%	14.6%	9.3%	40.3%	13.4%





Fig. 6-7 Diagnosis probability compared to BEMS data (1)





Fig. 6-8 Diagnosis probability compared to BEMS data (2)

6.2.2. 工場 B

6.1.2.にて訓練された CNNs を用いて 2014 年の BEMS データを診断した (Fig. 6-9, Table 6-4)。2013 年と 2014 年において大きな負荷の変動や制御変更は見られず、2013 年の負荷条件等をもとに作成した不具合データの特徴は 2014 年の BEMS データの診断に適用できるものとした。

各不具合の診断確率の分析に際して複数の不具合が同時に生じている可能性を考慮し、最も高い確率で診断された不具合のみが生じているとは判断せず、CNN が BEMS データにおいて各不具合の特徴を当該確率にて認識し、診断された不具合に起因する影響が BEMS データ上に少なからず現れていると解釈した。ただし、より診断確率の高い方が、不具合の特徴がよりデータに現れていると捉え、主に診断された F4, F7, F10, F11, F39 を対象に以下の分析を行った。

F4 に関して、6 月から 7 月において二次冷水流量が大きいにもかかわらず冷凍機が 1 台で運転されていた (Fig. 6-10(a)破線部内、以下同様)。冷凍機運転台数が 2 台に増段しない理由は、台数制御の流量閾値が設計値よりも高くなっていたためと推測される。6 月、7 月は F4 が診断された時期と重なるため、適切に診断がなされたと判断できる。なお、4 月中旬から F4 の診断確率は徐々に上昇しており、二次冷水流量の増加に伴ってこのような診断結果になったと考えられる。

1 月から 5 月、8 月から 9 月上旬において TR2 冷水流量が設定値と乖離していた (Fig. 6-10(b))。この時期は F7 が診断された期間と重なる。F7 はポンプインバータ下限値が大きい結果、流量を設定値通りに制御できなくなる不具合であるが、設定値と実際の値との乖離からこのように判断したものだと考えられる。1 月から 5 月において TR2 は稼働しておらず、流量は本来 0 であるべきだが、流量の値が生じていた。この症状はセンサに原因があると考えられるが、設定値との乖離という意味で F7 が診断されたと考えられる。

1 月から 5 月、8 月から 9 月上旬と 10 月から 12 月では TR1 冷却水ポンプインバータ周波数が 69.8%で一定となっていた (Fig. 6-10(c))。この期間は F10 が診断された時期と重なる。この不具合は 2.2.6.においても明らかになっていたものである。この時、TR1 冷却水流量は設定値に対して過大となっていた (Fig. 6-11(a))。制御仕様書では、冷却水ポンプインバータ周波数の下限値は 45%であったが、BEMS データ上では 69.8%となっていたためこのような制御状態になっていたと考えられる。不具合データベースにて想定した下限値は 90%であったが、不具合の傾向が同じであれば、程度が想定に達していなくとも診断されることが示唆された。シミュレーション上では下限値が 45%であっても適切に制御がなされたため、不適切なチューニングが放置されていると考えられる。

6 から 11 月は TR2 冷却水流量が設定値に対して乖離していた (Fig. 6-11 (b))。診断結果としては、8 月から 11 月にかけて流量が適切に制御できない F11 の確率が生じた。なお、この期間は TR2 が稼働しておらず、本不具合は冷却水流量センサの誤差である可能性もある。そのため、BEMS データのみからではこの不具合は原因が設定値、流量センサ、電力セ

ンサ、または BEMS のデータ収集機構にあるかは不明であり、これを明らかにするために
は実際に現場にてシステムの状態を直接確認する必要がある。しかし、本検討によって TR2
の冷却水まわりに何らかの不具合が生じていることは判明した。なお、この不具合に関して
は、より不具合データベースを拡張することで診断が可能になると考えられる。

F39 に関しては、夏季以外の一年間を通して診断確率が生じていた。F39 は冷却塔出口温
度センサに誤差が生じる不具合であるが、これによって冷却塔ファンの稼働は抑えられる。
F0, F39 のシミュレーション結果と BEMS データにおける冷却塔消費電力を比較すると、
F39 は F0 に対して冷却塔消費電力が小さく、BEMS データに近かった (Fig. 6-11(c))。なお、
夏季において F39 が診断されなかったのは F11 と同様、F4 がシステムへの影響が大きいた
めだと考えられる。

本手法による診断結果は 1 日単位で出力されるため、日々の運用においては診断確率の
高い不具合から、関係する BEMS データを分析することで、その不具合の発生を効率よく
確認可能であることが示された。なお、工場 B では事務所 A と異なり各不具合と F0 の差を
不具合データベースとして CNNs に与え、その特徴が学習されるため、F0 を項目として診
断確率を算出することはできない。そのため、不具合がそもそも生じているか判断を行う不
具合検知は 4 章で述べたような手法により行う必要があることに留意すべきである。

対象期間において、不具合が修繕されたという記録はみられなかったため、今回診断され
た不具合はシステムが潜在的に有している不具合だと考えられる。一年間にわたる CNNs に
よる診断と BEMS データ分析結果を比較したことで、これらの不具合は常にデータから存
在が明らかになるのではなく、負荷や外気湿球温度といった運用条件によってデータに発
現または潜伏することが明らかになった。よって、本研究で示した前処理に従う CNNs によ
る FDD 手法は、BEMS データにおける不具合の発現状況を捉えることが可能であることが
示された。




Fig. 6-9 Diagnosis probability for Factory B.

Table 6-4 Average diagnosis probabilities for Factory B.

Label	F1	F2	F3	F4	F5	F6	F7	F8
Average diagnosis probability [%]	1.4%	0.0%	0.0%	29.2%	0.8%	1.3%	10.3%	0.0%
Label	F9	F10	F11	F12	F13	F14	F15	F16
Average diagnosis probability [%]	0.0%	18.7%	12.3%	0.0%	0.0%	0.0%	0.0%	0.1%
Label	F17	F18	F19	F20	F21	F22	F23	F24
Average diagnosis probability [%]	0.2%	1.0%	1.4%	0.0%	0.2%	0.0%	0.0%	0.9%
Label	F25	F26	F27	F28	F29	F30	F31	F32
Average diagnosis probability [%]	1.1%	2.5%	0.5%	0.0%	0.0%	0.0%	1.9%	0.1%
Label	F33	F34	F35	F36	F37	F38	F39	
Average diagnosis probability [%]	0.0%	0.8%	3.1%	0.0%	0.0%	0.0%	12.2%	



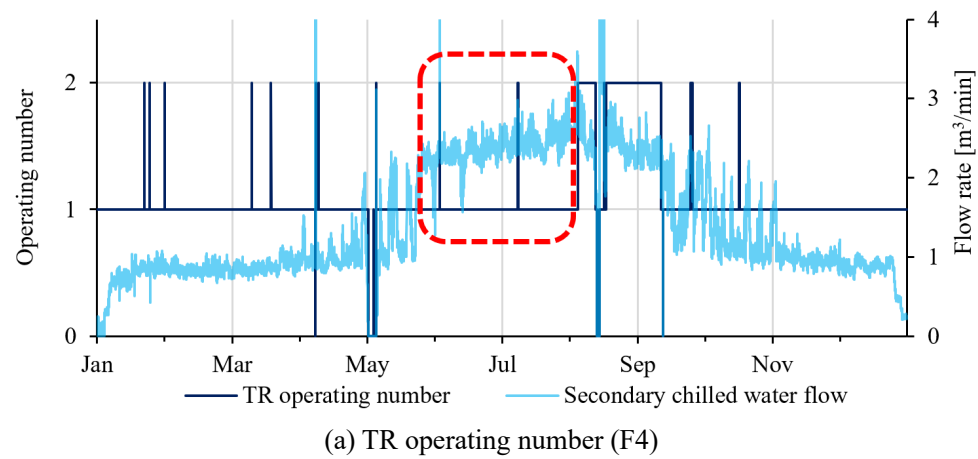


Fig. 6-10 BEMS data analysis referring to the diagnosis probability for Factory B. (1)






Fig. 6-11 BEMS data analysis referring to the diagnosis probability for Factory B. (2)

6.2.3. 前処理と学習・診断結果に関する一考察

本研究で提案した CNNs を利用した FDD 手法において、詳細なシミュレーションによる不具合データベースの作成が適切な診断には重要であった。診断したい不具合を含んだシステム挙動を算出することで、CNNs に不具合の特徴を学習させることが可能となるためである。しかし、CNNs に学習データとして不具合データベースを与える際、5.3.で記述したような前処理が必要であった。

機械学習手法へ学習データを与える前に行われるデータの前処理は *normalization*, *standardization* と呼ばれ、その手法によって機械学習の精度が左右されるため、適切な手法の選択が非常に重要である[1][2]。そこで、以下の Case1 から Case4 (Case4 は 5.3.の手法と同じ) の前処理手法による学習・診断結果を比較することで、5.3.で用いた手法の妥当性を検証した。なお、各ケースで共通して、事前にシミュレーションの入力値である 2013 年の BEMS データにて欠損のあった 5 日間のデータを除去し、不具合データを 1 種類当たり 360 とした。

前処理手法：

(1) Case1

Case1 では各項目について Eq. (6-1)の正規化を行った。この時、39 種類の不具合を 360 ずつ用いたため、学習データは合計 14,040 となった。BEMS データを診断する際も同様に正規化を行い、その結果 1 を超えた場合は 1, 0 を下回った場合は 0 とした。

$$x_{normalized,A} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad \text{Eq. (6-1)}$$

Where $x_{normalized}$ is the normalized array, x is the array before normalization, $\min(x)$ is the minimum value in x , and $\max(x)$ is the maximum value in x .

(2) Case2

Case1 では、不具合の影響が出ていない項目についても値の変動の特徴を CNN が学習する可能性があり、学習の効率は良くないと考えられる。そこで、Case2 から Case4 では各不具合データから不具合がない状態のデータ (F0) を引いた値を Eq. (6-1)と同様に正規化したものを学習データとした (Eq. (6-2))。データ量は Case1 と同様に 14,040 であった。

$$x_{normalized,B} = \frac{x - x_0 - \min(x - x_0)}{\max(x - x_0) - \min(x - x_0)} \quad \text{Eq. (6-2)}$$

Where $x_{normalized,B}$ is the normalized array, x is the array before normalization (F1~F39), x_0 is the array before normalization (F0), $\min(x - x_0)$ is the minimum value in $x - x_0$, and $\max(x - x_0)$ is the maximum value in $x - x_0$.

(3) Case3

負荷条件等の運用条件によっては、システムが不具合を抱えていてもその挙動には特徴が現れない場合がある。そのようなデータは識別器の学習、すなわち特徴抽出に障ると考えられる。そこで、計算条件としては不具合が組み込まれているが、制御状態としては不具合が極力現れていないデータを学習データから取り除くことで精度向上を図った。具体的には、360日のシミュレーション出力のうちの供給熱量、消費電力量、SCOPのすべてにおいてF0と各不具合データの値が同値（誤差0.01%未満）となった日を学習データから除外した（Table 5-4 参照）。

実際の運用において、冷水や冷却水ポンプのインバータ下限値は冷凍機の故障停止予防のために設定される場合があるが、本研究ではインバータ下限値が小さすぎる場合にどのような不具合状態が生じるか算出するためにF8, F9, F12, F13を設定していた。しかし、これらの不具合はシミュレーションにおける発生日数が非常に小さく、実際にも生じにくいはずだという判断のもと、発生日数が計算対象日数である360の1割以下であるF8, F9, F12, F13, F29を学習対象から除外した。その結果、データ量は8,933となった。

(4) Case4

Case3では各ラベルにおいて学習データの数異なるため、学習データが多い不具合は少ない不具合に対して特徴をより多く学習される可能性がある。そこで、不具合の発生日数が最も少なかったF17に合わせ、全ての不具合についてランダムに81日分抽出したものを学習データとした。その結果、ひとつのCNNが学習時に用いるデータ量は35種類の各不具合データを81日分で2,835となった。

学習結果：

Table 6-5に学習時のValidationデータの精度を示す。Case1が最も正解率が低く、発生日数が小さいF8やF12, F29の精度は10%に満たず、これらを含めて精度が50%未満のものは10種類であった。発生日数の小さいF8, F9, F12, F13, F29を除いた平均精度は、Case2（85.7%）がCase1（80.7%）に対して向上し、データの前処理として各不具合データと不具合がない場合との差を取ることで、不具合の特徴をより学習できることが示された。しかし、精度が50%未満のものは7種類あり、不具合によっては適切に学習がなされていなかった。Case3とCase4は平均精度が98%を超え、各不具合の中で最も低い精度は87.9%(Case3, F15)

であった。Case1 や Case2 では不具合が生じていないデータも学習させていたため不具合種類によっては著しく精度が低かったが、Case3 や Case4 ではその問題が解消された。Case4 の各不具合の中で最も低い精度は 91.5% (F37) であり、Case3 よりも不具合ごとの精度のばらつきは小さい結果となった。

Table 6-5 Validation performance

Label	Case1	Case2	Case3	Case4
F1	94.8%	99.2%	99.5%	99.7%
F2	43.1%	71.8%	99.7%	99.0%
F3	51.5%	96.8%	99.0%	99.2%
F4	76.5%	70.1%	100%	99.7%
F5	93.3%	88.0%	99.6%	99.5%
F6	99.6%	99.6%	99.8%	99.5%
F7	67.1%	67.4%	98.0%	98.7%
F8	8.1%	69.3%	-	-
F9	39.3%	39.1%	-	-
F10	99.2%	99.4%	99.1%	96.9%
F11	26.8%	29.8%	95.0%	92.8%
F12	7.3%	42.9%	-	-
F13	36.8%	35.7%	-	-
F14	97.7%	100%	100%	100%
F15	36.6%	36.9%	87.9%	92.3%
F16	97.3%	99.7%	99.9%	100%
F17	53.6%	67.8%	96.2%	97.7%
F18	97.4%	99.4%	100%	100%
F19	99.2%	99.8%	99.8%	94.4%
F20	96.1%	99.4%	100%	100%
F21	98.2%	99.9%	98.8%	99.2%
F22	99.0%	99.6%	99.9%	100%
F23	99.3%	100%	100%	100%
F24	98.4%	99.7%	100%	99.0%
F25	99.5%	99.8%	99.9%	98.5%
F26	99.4%	99.1%	99.7%	98.5%
F27	99.3%	99.4%	100%	100%
F28	51.3%	52.2%	96.3%	96.9%
F29	4.8%	62.9%	-	-
F30	98.1%	99.5%	99.7%	100%
F31	98.8%	99.9%	100%	99.5%
F32	98.6%	99.4%	99.9%	100%
F33	37.2%	40.1%	94.1%	95.6%
F34	96.4%	99.4%	100%	100%
F35	98.6%	99.8%	99.3%	97.4%
F36	95.2%	98.2%	99.4%	99.2%
F37	22.9%	21.5%	88.9%	91.5%
F38	99.2%	99.4%	99.8%	98.2%
F39	98.7%	99.5%	99.9%	98.7%
Average*	80.7%	85.7%	98.5%	98.3%

*Average was calculated without F8, F9, F12, F13, F21.


診断結果：

各前処理が施された不具合データベースを用いて訓練された CNNs を用い、2014 年の BEMS データを診断した (Fig. 6-12, (d)は Fig. 6-9 の再掲)。


Case1 では Case4 にて主に診断された F4, F7, F10, F11, F39 のうち、F10 以外がほとんど診断されなかった。Case2 では F10 がほぼ診断されなくなり、F10 以外が診断された。Case3 では Case2 に対して F4 がより診断されたことに加え、F10 が診断された。Case4 では Case3 に対して全体的に F4, F7, F11 の診断確率が増加した。なお、5 月 3 日から 6 日、8 月 14・15 日はその前後と診断の傾向が異なるが、データに欠損があったため適切な診断がなされなかったと考えられる。

以上より、Table 6-5 にあるように Case3 と Case4 では学習時の精度はほぼ同じであるにも関わらず、学習の際のデータの前処理によって BEMS データの診断結果が変化することが確認された。


6.2.2.で記述した通り、Case4 による診断結果は詳細な BEMS データ分析と整合性がみられた。診断結果を見ると発生日数の少ない F11 の診断確率が Case4 は Case3 よりも高かった。このような傾向は生じている不具合を見落とすことにつながるため、本検討では Case3 よりも Case4 の方が適切に診断されたと判断した。その一方で、Case4 における 12 月の F7 や 4 月の F11 は診断されているが BEMS データ上からはその特徴は見られなかった。このような誤診の改善は今後の課題である。




(a) FDD result by Case1



(b) FDD result by Case2



(c) FDD result by Case3



(d) FDD result by Case4 (The same as Fig. 6-9)

Fig. 6-12 Comparison of FDD result with various preprocessing

6.3. 考察と今後の課題

従来の BAS に導入されている不具合検知の機能は、対象が閾値を超えた場合の警報が主であった。この手法はシステムが停止に陥るような故障等には非常に有効であるが、そうではない不具合に対しては閾値の適切な設定が必要であり、さもないと検知された段階で不具合は深刻化していることとなる。閾値を設けずに不具合をデータから明らかにする場合、運転条件によってはシステム挙動上には僅かな兆候しかもたらさない不具合を日々の運用においてオペレータが識別することは困難である。

このような現状に対し、本提案手法は FDD を分類問題として取り扱うことで様々な不具合の発生可能性を診断確率という数値で提示することができる。オペレータはその情報に基づいて診断確率の高い順にサブシステムのデータ分析や点検を行うことで、大きな遅れなく不具合を検知・診断することが可能になると考えられる。

工場 B の診断結果 (6.2.2.) に関して、BEMS データ分析上では 7 月付近では F4 と F11 両方の特徴がみられたが、診断結果は F4 が約 96%, F11 が 0 から 3.6% であった。6.1.3. の考察において、不具合が複数生じている場合、不具合の程度が想定を上回らない限り不具合の影響の大きい方が、診断確率も大きくなることがわかっている。F4 の冷凍機台数が 2 台となる不具合は本来 1 台運転すべき負荷時に 2 台で運転してしまう状況を指し、他の不具合に対してシステム全体への影響が非常に大きい。そのため、他の不具合の影響をかき消してしまった可能性がある。

以上を踏まえると、本手法を用いて不具合を修復したのちに、隠れていた不具合も新たに診断され、最終的に不具合のないシステムへと性能を向上させることが可能になると考えられる。しかし、不具合の修復にかけられるコストは限られている場合があるため、どの不具合から修復するか判断を行う必要がある。

そのため今後の課題として、不具合を程度まで含めて同定することで、不具合修復時の性能向上を定量化可能とすることが挙げられる。例えば、不具合データベース作成時にシミュレーションに与えたパラメータを変数として、BEMS データとシミュレーション結果が一致するよう各パラメータを探索する手法が考えられる。しかし、工場 B での検討用に不具合種類が数十に及ぶと探索に非常に時間を要するため、現実的ではない。そのため、まず本手法により不具合種類を絞り込むことは有意義であると考えられる。

また、本手法の実装に向けて、実際に生じやすい不具合の調査も必要である。工場 B ではシステム構成上最大限考えうる不具合を想定したが、より実務的な観点から不具合の設定を行うことで、実システムへの適用性が高まることが期待される。また、シミュレーションでは機器が非運転の場合は計算を行っていないが、実際は何らかの値が計測される。そのため、機器が非運転の場合はその機器に関係する値を 0 にするといった処理を行うことで診断性能が向上する可能性がある。

当然であるが、本手法では想定外の不具合を診断することはできない。しかし、第 4 章において何らかの不具合が検知されたにも拘わらず診断された不具合のシステム性能への影

響が小さい場合、想定外の不具合が生じていると判断が可能である。その場合は手作業によるデータ分析を通して、熱源システムの想定不具合種類を拡充し、データベース作成の知見が蓄積されることが望ましいと考えられる。加えて、計測レンジの関係で粒度の荒い BEMS データは不具合の特徴が表れにくくなるため診断精度が低くなると考えられる。不具合の特徴を把握できるよう、計測レンジはあらかじめ確認する必要があるが、この課題は BEMS データの前処理という意味でデータクレンジングに位置づけられると考えられる。

6.4. 小括

本章では、前章で作成した不具合データベースを用いて CNNs を訓練し、学習済み CNNs を用いて BEMS データにおける不具合検知・診断を行い、以下の知見を得た。

①CNNs の学習特性の確認

画像化した不具合データベースを CNNs に学習させた。シミュレーションにより作成した様々な程度の不具合データを診断させた結果、不具合データベース作成時に想定した不具合の程度が診断結果に影響を与えることがわかった。具体的には、感度高く診断したい不具合の場合は、不具合の程度を小さめに想定することが有効であることがわかった。

②データ前処理の検討

学習データの前処理手法のケーススタディを行うことで、診断結果から適切な前処理手法を検討した。工場 B の検討では想定した不具合種類が 39 種類と多かったため、不具合条件を与えない計算結果との差をとり、不具合が生じているデータのみを抽出し、これを均等に CNNs に学習させることが有効であることがわかった。

②BEMS データの診断による有効性の確認

BEMS データを学習済み CNNs に診断させ、診断結果と BEMS データとを比較した。その結果、負荷や外気温湿度といった運転条件によってデータに発現する不具合の種類は変化し、ある不具合の診断確率が生じているとき、BEMS データにも不具合の特徴がみられることが確認され、診断結果の妥当性が示された。ただし、本手法による診断結果は不具合の程度を直接導くことができないため、不具合程度の同定は今後の課題である。

Acknowledgements

本章の検討は、東京電力ホールディングス株式会社 (Tokyo Electric Power Company Holdings, Inc.), JSPS Research Fellow, Grant number JP17J08140 と JSPS KAKENHI, Grant Number JP18K13879 の支援を受けて遂行された。

参考文献

- [1] Jayalakshmi T., Santhakumaran A. : Statistical normalization and back propagation for classification, International Journal of Computer Theory and Engineering, Vol. 3, No. 1, pp.1793-8201, 2011.
- [2] Mohamad Ismail Bin, Usman Dauda : Standardization and its effects on K-means clustering algorithm, Research Journal of Applied Sciences, Engineering and Technology, Vol. 6, No. 17, pp.3299-3303, 2013.

本章に関連する発表論文（前章と共通）

[学術雑誌・査読有]

1. 宮田翔平, 赤司泰義, 林鐘衍, 呉楊駿, 田中勝彦, 田中覚, 桑原康浩, 機械学習を用いた空調熱源システムの不具合検知・診断 第 1 報—シミュレーションによる不具合データベース作成と畳み込みニューラルネットワークによる不具合検知・診断, 空気調和・衛生工学会論文集, 第 43 巻, 第 257 号, pp.11-20, 2018 年
2. 宮田翔平, 赤司泰義, 林鐘衍, 本村彬, 田中勝彦, 田中覚, 桑原康浩, 機械学習を用いた空調熱源システムの不具合検知・診断 第 2 報—診断性能向上のための不具合データの前処理と BEMS データへの適用, 空気調和・衛生工学会論文集, 第 43 巻, 第 261 号, pp.1-9, 2018 年
3. Shohei MIYATA, Jongyeon LIM, Yasunori AKASHI, Yasuhiro KUWAHARA, Katsuhiko TANAKA Fault detection and diagnosis for heat source system using convolutional neural network with imaged faulty behavior data, Science and Technology for the Built Environment, Published online: 03 Sep 2019

[国際会議・査読有・口頭]

4. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Katsuhiko TANAKA, Satoru TANAKA, Yasuhiro KUWAHARA, Model-Based Fault Detection and Diagnosis Using Convolutional Neural Networks in Heat Source System with Water Thermal Storage Tanks, the 4th Asia Conference of IBPSA – ASim 2018, ID 523, Hong Kong, Dec. 2018
5. Shohei MIYATA, Yasunori AKASHI, Jongyeon LIM, Yasuhiro KUWAHARA, Katsuhiko TANAKA, Model-based Fault Detection and Diagnosis for HVAC Systems Using Convolutional Neural Network, 16th IBPSA International Conference Building Simulation – BS 2019, Rome Italy, August 2019

第7章

最適制御

7.1. 本章の背景と目的

7.1.1. 低炭素化とデマンドレスポンス

二酸化炭素（Carbon Dioxide, CO₂）の排出量削減を目的として、太陽光発電に代表される再生可能エネルギーが近年大幅に普及している。その一方で、昼間の余剰電力といった電力の需給バランスに課題が生じてきている。従来の電力システムでは、需要の変動は火力発電所または揚水発電によって吸収されていたが、再生可能エネルギー普及後の電力システムにおいては、天候などの外乱によって供給側の出力も変動するため、需要側がその変動に対応する必要がある。例えば、アメリカはカリフォルニア州では夕方に太陽光発電が急減する一方で家庭の電力需要が増加するため相対的な電力需要が急増する現象（ダックカーブ）が問題となっている[1]。日本でもすでに、太陽光発電が需要に対して過多となり解列させる事例が生じている[2]。

デマンドレスポンス（Demand Response, DR）は、もともと電力負荷平準化を目的とした需要調節の方策としてこれまで研究や実証がなされてきた[3] [4]。米国 DOE と日本の経済産業省資源エネルギー庁による DR の定義は以下の通りである。

Changes in electric usage by end-use customers from their normal consumption patterns in response to changes in the price of electricity over time, or to incentive payments designed to induce lower electricity use at times of high wholesale market prices or when system reliability is jeopardized.[5]

需要家エネルギーリソース（DSR）の所有者もしくは第三者が、需要家エネルギーリソース（DSR）を制御することで、電力需要パターンを変化させること。[6]

米国 DOE による定義が示す通り、DR には①電力価格設定によるもの（ダイナミックプライシング）、②負荷（機器）の直接操作（アグリゲータ経由含む）、③市場取引型、の 3 種類が想定されている。日本では主に②のアグリゲータによる機器操作が DR として導入が進められている。この手法は DR 量や時刻に対する信頼性が高いものの、需要家にとって好ましくないエネルギー利用状況となる場合がある。例えば、建築物による代表的な DR として、室内温度設定値の変更が挙げられる[7] [8]。もともと建築物が最適な状態で制御されているとした場合、DR により強制的に温度設定値を変更することは居住者の快適性を損なう可能性がある。

7.1.2. 本章の目的と手法

建築物において DR を行う際、居住者への影響を最小限にとどめることが今後より重要となる。そのためには、各建築物が能動的に系統の状況を参照しながら機器制御を行うことが必要である。DR に参加する建築物が増加し、それらが系統の状況に配慮した機器制御を行うことで、将来的に再生可能エネルギーの導入拡大が可能となるためである。

この形は、3 種類の DR のうち、①電力価格設定によるもの、③市場取引型、によって達成されると考えられる。特に市場取引型は需要家が DR を行うか否かを決定できるため、居住者の快適性を最大限維持可能であると想定される[9]。しかし、現段階では市場が健全な状態にあるとはいいがたいという課題がある[10]。

DR は電力系統の安定化がもともとの目的であるが、再生可能エネルギーの導入拡大への寄与による低炭素化への貢献も期待される。そこで、①電力価格設定による DR を、CO₂ 排出係数を考慮した機器制御とすることで、CO₂ 排出量を最小化する機器制御を検討し、その効果を定量化することを本章の目的とする。

具体的には調整力を活用し、動的な CO₂ 排出係数を考慮することで CO₂ 排出量が最小となるように冷凍機の運転を最適化する。なお、本制御手法を、低炭素化を目的とした DR という意で Carbon Activated Demand Response (CADR) と呼ぶこととする。なお、類似研究としてオンサイトの太陽光発電、コジェネレーションシステム、蓄熱槽を活用した最適制御の検討が行われているが[11]、本検討は建築物が接続する系統全体の動的な排出係数を考慮するものである。

また、本章では建物単体を対象とした検討を行うが、本手法が普及した結果として再生可能エネルギーの導入がどの程度拡大可能であるかは今後明らかにする必要がある。

7.1.3. 対象システム

本章では、調整力を活用した低炭素制御を検討するため、蓄熱槽を有する事務所 A の熱源システムを対象とした。

7.2. 動的二酸化炭素排出係数の推定

本検討において、動的 CO₂ 排出係数は、CO₂ 排出量を発電量で割った値[kg-CO₂ / kWh]として定義した。一般的に、排出係数は各電力会社が年間平均値として公表している。しかし本来排出係数は再生可能エネルギー等により常に変動するはずであるため、それを動的 CO₂ 排出係数として1時間ごとに推定した。

本研究では日本国内で再生可能エネルギーの普及が進む九州エリアでの動的 CO₂ 排出係数を推定・利用した。九州エリアは日照条件が良く土地も安価であることから、固定価格買い取り制度の開始以降、太陽光発電の導入が拡大した。そのため、九州の需給状況は近い将来の日本全体の状況を表すとして検討を進めた。

動的 CO₂ 排出係数の推定を、以下の 1)～3)を用いて行った。

- 1) 1時間毎の地域需要、火力、原子力、水力、地熱、バイオマス、太陽光、風力、揚水、および相互接続電力データ[12]
- 2) 火力発電の各タイプにおける CO₂ 排出係数[13] (Table 7-1)
- 3) 2017年4月時点で稼働していた九州電力の石炭、液化天然ガス、石油の火力発電の設備容量と種類[14] (Table 7-2)

まず、1)と2)から火力以外の電源による排出係数を算出した。火力発電による排出係数は石炭や液化天然ガス等で異なるため、3)と1)における火力の発電量から推定した。なお、運転順位は Table 7-2 に示す順とし、推定期間は2017年4月1日から2018年3月31日までの1年間とした。九州エリアには九州電力以外の電力会社も火力発電所を有しているが、これらの発電も考慮した。

Table 7-1 電源種別排出係数

Type	Coefficient [kg-CO ₂ / kWh]
Coal	0.864
LNG (Combined)	0.376
LNG	0.476
Oil	0.695

Table 7-2 Type of power plants

Type	Name	Commencement	Capacity (kW)	Maximum generation (MWh)
Coal	Karita-1	2001	360,000	324
	Reihoku-1	1995	700,000	630
	Reihoku-2	2003	700,000	630
	Matsuura-1	1988	700,000	630
LNG (Combined)	Shin'oita-1	1991	115,000	104
	Shin'oita-2	1991	115,000	104
	Shin'oita-3	1991	115,000	104
	Shin'oita-4	1991	115,000	104
	Shin'oita-5	1991	115,000	104
	Shin'oita-6	1991	115,000	104
	Shin'oita-7	1991	217,500	196
	Shin'oita-8	1991	217,500	196
	Shin'oita-9	1991	217,500	196
	Shin'oita-10	1991	217,500	196
	Shin'oita-11	1991	245,000	221
	Shin'oita-12	1991	245,000	221
	Shin'oita-13	1991	245,000	221
	Shin'oita-14	1991	459,400	413
LNG	Shinkokura-1	1978	600,000	540
	Shinkokura-2	1979	600,000	540
	Shinkokura-3	1983	600,000	540
Oil	Buzen-1	1987	500,000	450
	Buzen-2	1987	500,000	450
	Ainoura-1	1983	375,000	338
	Ainoura-2	1983	500,000	450
	Karita-2	1982	375,000	338
	Sendai-2	1985	500,000	450
	Sendai-1	1974	500,000	450

動的 CO₂ 排出係数の年間推移をみると、夏季や冬季の変動が中間期に対して小さい結果となった (Fig. 7-1)。夏季や冬季は需要が大きく、火力による発電量が増加するため、相対的に再生可能エネルギーの発電量が小さくなったためと考えられる。また、推定した 1 年間のうち、最も低い値は 5 月 14 日 14:00 の 0.096 kg-CO₂ / kWh であり、最も高い値は 3 月 19 日 0:00 の 0.560 kg-CO₂ / kWh であった (Fig. 7-2, Fig. 7-3)。5 月 14 日は昼間の値が夜間の値よりも明らかに低く、太陽光発電による影響が非常に大きかったと考えられる。対して、3 月 19 日は一日を通して値が高かったため、昼間も再生可能エネルギーによる発電量が小さかったと推察される。

このように状況によって CO₂ 排出係数は大きく変動するため、低炭素化には動的 CO₂ 排出係数を考慮した機器制御が不可欠であると考えられる。




Fig. 7-1 Dynamic coefficient of CO₂ emissions (FY2017)




Fig. 7-2 Minimum coefficient of CO₂ emissions (May 14th)




Fig. 7-3 Maximum coefficient of CO₂ emissions (March 19th)

7.3. 従来制御

対象システムでは、夜間（22:00～8:00）の方が日中（8:00～22:00）よりも電力が安いいため夜間に蓄熱運転が行われる（Fig. 7-4）。22 時になると各冷凍機の効率が最も高くなるような負荷率が設定され、満蓄になるまで蓄熱される。なお、昼間に残蓄熱量が不足した場合にも冷凍機は稼働して追掛け運転を行う。

上記の夜間蓄熱制御からパラメータを変更するだけで可能な制御として、蓄熱開始時刻を 8 時と設定する昼間蓄熱もケーススタディの対象とした（Fig. 7-5）。

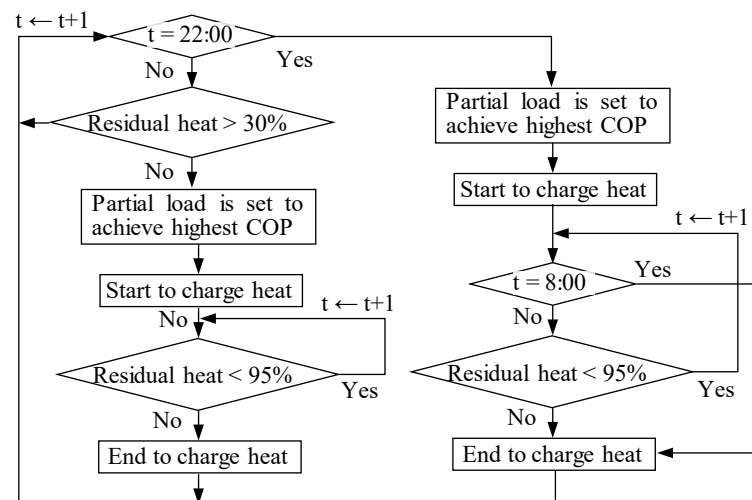


Fig. 7-4 Conventional method (storage from 22:00)

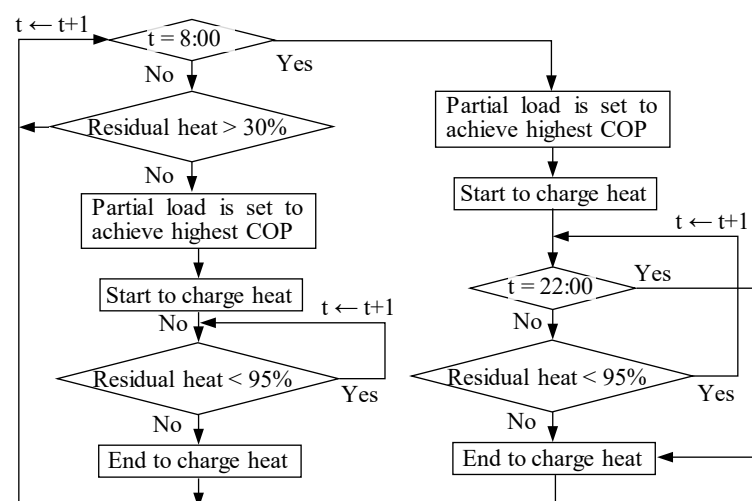


Fig. 7-5 Conventional method (storage from 8:00)

7.4. Carbon Activated Demand Response (CADR)

毎時刻変動する動的 CO₂ 排出係数を考慮し、CO₂ 排出量を最小化する制御 (CADR) を本節で提案する。

CADR では基本的に排出係数が小さい間に蓄熱し、大きい間に放熱することを目指す。しかし、熱源システムとして適切に熱を供給するためには、排出係数と熱負荷、残蓄熱量のバランスを考慮して冷凍機を運転する必要がある。例えば、蓄熱槽が満蓄の時に冷凍機が稼働すると、冷凍機の冷水入口温度が低下し、冷凍機は保護停止してしまう。また、残蓄熱量が不足しているにもかかわらず冷凍機が稼働しない場合、二次送水温度が上昇して室内環境へ悪影響を及ぼしてしまう。

従来は上記のような不具合状態を防ぐために事前に制御ロジックが組まれ、運用段階で適宜修正される。しかし、日々変化する負荷や動的 CO₂ 排出係数に対し、不具合を避けながら対象システムがもつポテンシャルを最大限に発揮させる制御を実行することは容易ではない。

7.4.1. Model Predictive Control, MPC

そこで、モデル予測制御（Model Predictive Control, MPC）を用いた冷凍機の最適制御を CADR として提案する。MPC とは、システムの予測挙動に基づき次時刻の制御入力を決定するフィードバック制御手法である[15]。化学プラントといったプロセス産業においては 1960 年代から MPC のもととなるアイデアが存在しており、今日では広く用いられている[16][17]。その一方で、空調システムは非線形システムであり負荷が時刻変動するといった特性をもつため MPC の適用が容易ではなかったが、計算機性能の向上も相まって近年は盛んな研究がなされている[18]。

MPC では、まずシステムモデルを用いて最適な制御量を求める（Fig. 7-6）。このシステムモデルに第 3 章にて構築したシステムシミュレーションを、制御量を求める最適化器には Particle Swarm Optimization（PSO）を用いた。本来であれば制御量を実際のシステムに入力するが、本検討では実装には至っていないため制御量の入力先もシステムシミュレーションとした。なお、実装においてはモデルと実システムとの乖離が存在するため、それを調節することが肝要である[19]。しかし、本検討ではまず熱源システムにおいて詳細なシステムシミュレーションを用いた MPC による低炭素制御の効果を算出するためにモデルと実システムの乖離は考慮しないこととした。なお、詳細なシステムシミュレーションを用いることで、最適解の探索時に不適切な制御挙動（不具合）を確実に避けることが可能になると考えられる。

MPC では予測期間（Prediction horizon, Moving horizon）を設けてその期間内での最適解のうち、次時刻の出力のみを用いる（Fig. 7-7）。本検討では制御周期を 2 時間とし、偶数時刻 $t_0:00$ になった時に最適解の探索を開始する。探索に要する時間は 2 時間以内として予測期間を $(t_0+2):00$ から $(t_0+48):00$ までの 46 時間とした。

操作変数は冷凍機の発停（On/Off）とし、問題を簡単にするために冷凍機は蓄熱系（TR1–TR3）3 台すべてが同時に稼働または停止するものとした。なお、事務所 A の熱源システムには直送系冷凍機 TR4 が含まれるが、本検討では稼働対象外とした。冷凍機負荷率は冷却水入口温度から COP が最も高くなるよう決定されるものとし、冷凍機に付随する冷水ポンプや冷却水ポンプや負荷率に従い制御されるものとした。本検討における制御周期が 2 時間であるのは、冷凍機を頻繁に発停することは好ましくないためである。

MPC を実行するためには現実の制御周期よりも短い時間に最適解を探索する必要があるため、ニューラルネットワークによってモデルが作成される場合がある[20][21][22]。しかし、ニューラルネットワークには、学習データに含まれる範囲内の入力値でのみ適切な計算が可能であるという制約がある。そのため様々な設定値で生じるシステム挙動を事前に算出して学習データとする必要がある。空調システムにおいては各ポンプや弁といった様々な制御対象が一つのシステムに存在するため、学習データの算出に膨大な時間とデータ量が必要となってしまうため、ニューラルネットワークの利用は限定的な範囲の適用にとどめるべきである。

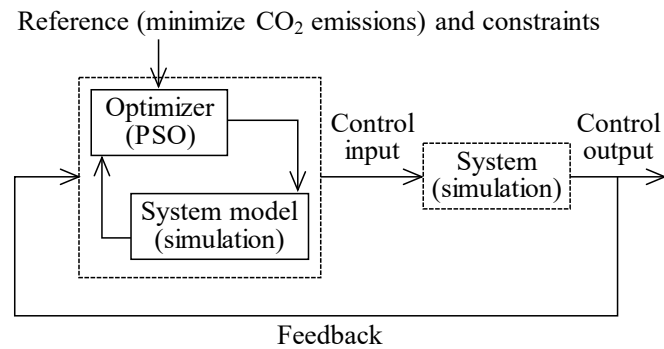


Fig. 7-6 Structure of calculation in Chapter 7

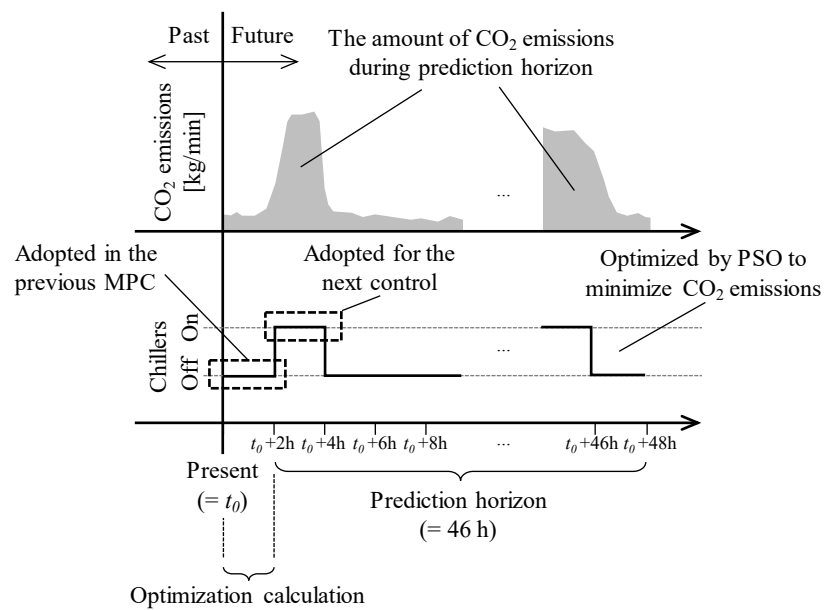


Fig. 7-7 Concept of MPC

さらに、最適解の探索時において、冷凍機や送水温度に関する不具合を避け、計算自体を効率化するために以下の制約条件を与えた。

- 1) 供給熱量と熱負荷の間の誤差を1%以下とする。
- 2) 二次送水温度（設定値 7°C）は、予測期間最初の2時間で90分以上8°Cを上回らないものとする。
- 3) 冷凍機の冷水入口温度が予測期間最初の2時間で90分以上7°Cを下回らないものとする。
- 4) 2), 3)をともに満たさず、予測期間最初の2時間の排出係数の平均値が0.300を下回る場合、次時刻の冷凍機をONとする。
- 5) 二次送水温度が計算開始時刻から48時間のうち、10%以上で8°Cを上回らないものとする。
- 6) 冷凍機の冷水入口温度が計算開始時刻から48時間のうち、10%以上で7°Cを下回らないものとする。

実際は負荷の予測には誤差が避けられない。そこで、MPCの入力値としての予測負荷と、実際の制御における負荷との間に誤差がない場合（Case1.0）、予測負荷の方が実際の負荷よりも10%大きい場合（Case1.1）、予測負荷の方が実際の負荷よりも10%小さい場合（Case0.9）のケーススタディを行った。熱負荷予測は24時間先までに関しては数多くの検討がなされ、それらの予測誤差（Mean Absolute Percentage Error, MAPE, Eq. (7-1)）は10%程度である[23] [24] [25] [26]。しかし、本検討では48時間後の予測負荷を用いるため、48時間後の予測誤差は少なくとも10%程度はあるものと仮定した。

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad \text{Eq. (7-1)}$$

Where N is the number of forecast results, y_i is the actual load and \hat{y}_i is the predicted load.

なお、動的排出係数については予測時と実際とで誤差を与えないこととした。本質的に低炭素化を目指す場合は熱負荷と同様に誤差を考慮すべきではあるが、本制御が実用化される際の社会制度を考慮すると、予測時の値を電力系統との契約値として需要家である建物が制御するという形がより自然だと考えられるためである。

7.4.2. Particle Swarm Optimization, PSO

粒子群最適化 (Particle Swarm Optimization, PSO) は最適解を探索するメタヒューリスティックス手法の一つである[27]。メタヒューリスティックス手法には遺伝的アルゴリズム (Genetic Algorithm, GA) などが含まれ、解の候補を徐々に最適と思われる点へ漸近させる[28]。収束条件を満たしたときに解の探索を終了するが、探索空間のすべてを網羅するわけではないため準最適解化とも呼ばれる。また、近年は量子コンピュータが現実化しており、今後は組み合わせ最適解の計算能力が格段に向上することが期待されている[29][30]。そのため、本検討では操作変数を冷凍機の発停のみとしたが、将来的には操作変数が拡大可能となることも期待される。

PSO では、粒子の位置 x と速度 v が Eq. (7-2), Eq. (7-3)に従い更新されることで、粒子群が探索空間において最も評価関数の良い点に収束する。なお、Eq. (7-2), Eq. (7-3)の w は 0.75, c_1 と c_2 は 0.3 に設定された。本章における目的関数は予測期間における CO₂ 排出量とした。

$$x \leftarrow x + v \quad \text{Eq. (7-2)}$$

$$v \leftarrow wv + c_1 r_1 (\hat{x} - x) + c_2 r_2 (\hat{x}_g - x) \quad \text{Eq. (7-3)}$$

Where x is the position of a given particle, v is its velocity of a particle, w is its inertial weight, c_1 and c_2 are acceleration constraints, r_1 and r_2 are random functions in the range [0,1], \hat{x} is the best position of the particle, and \hat{x}_g is the best position of all particles.

本検討では粒子の数を 16 とし、粒子の位置 x を予測期間（46 時間）における冷凍機の発停（1×23 の行列，1 を稼働，2 を停止）とした。 x を更新する際に，最も CO₂ 排出量の多い 3 つをランダムに更新し直し，最も CO₂ 排出量の小さい上位 4 つの差が 1%未満のときに収束したと判断した（Fig. 7-8）。なお，一回の最適値探索において位置の更新回数は 50 回を上限とした。

本章の最適化において要した時間は，最も長くて 25 分 8 秒であった。用いた PC は OS: Microsoft Windows 10 Home，プロセッサ: Intel(R) Core(TM) i7-7820X CPU @ 3.60GHz, 3600 Mhz, 8 cores，メモリ: 64.0 GB であり，MATLAB の parallel computing toolbox を利用した。

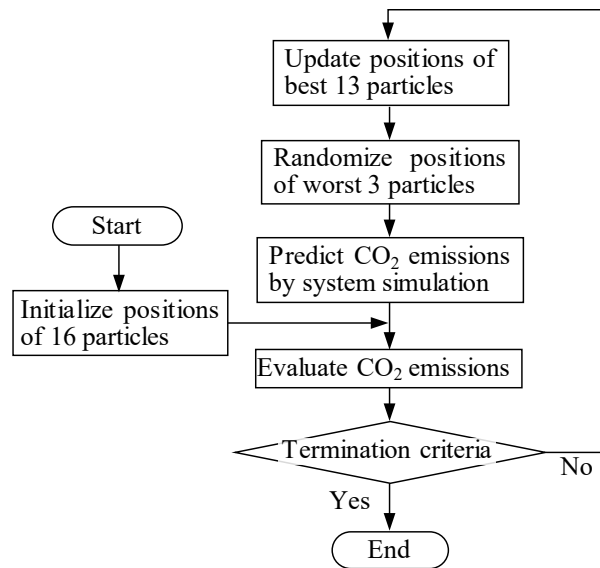


Fig. 7-8 Particle Swarm Optimization

7.5. 結果

対象期間の 1 週間における従来手法と CADR の計算結果を Table 7-3 に示す。なお、CO₂ 排出量と消費電力量は対象期間の開始時と終了時の残蓄熱量を考慮して補正を行った。結果として、CADR (Case1.0) は従来手法 (22 時蓄熱開始) に対して 46.77% の CO₂ 排出量削減効果を得られた。また、消費電力量に関しても CADR (Case1.0) の方が従来手法 (22 時蓄熱開始) に対して 2.55% 削減された。下水温度は夜間よりも昼間の方が高いため、昼間に多く冷凍機が稼働する CADR の方が消費電力は増加すると予想されたが、下水温度の変動が小さいことに加え、冷凍機冷水ポンプの余力で放熱用熱交換器に冷水が送られることで冷水一次ポンプの動力が削減されたためだと考えられる。

CADR における予測負荷を変動させたケーススタディでは、Case1.1 が Case1.0 よりも悪化したものの 8 時蓄熱開始のケースよりも改善がなされた。なお、Case0.9 の CO₂ 排出量が Case1.0 よりも削減された理由については後述する。


Table 7-3 Results for the target week

	A: Conventional (storage from 22:00)	B: Storage from 8:00	C: CADR (Case0.9)	D: CADR (Case1.0)	E: CADR (Case1.1)	Ratio (D to A)	Ratio (D to B)
Supplied heat [GJ] (=a)	919.6	919.6	919.5	919.5	919.5	0.00%	0.00%
Residual heat storage at 0:00 June 4th [GJ] (=b)	249.7	223.6	188.6	179.1	138.7	-	-
Residual heat storage at 23:59 June 11th [GJ] (=c)	238.0	215.7	195.1	195.2	238.3	-	-
CO ₂ emissions [10 ³ kg] (=d)	25.24	15.49	13.51	13.85	15.50	-	-
Revised CO ₂ emissions [10 ³ kg] (=d*a/(a+c-b))	25.57	15.63	13.41	13.61	13.99	-46.77%	-12.89%
Power consumption [MWh] (=e)	51.2	50.2	50.9	51.39	56.3	-	-
Revised power consumption [MWh] (=e*a/(a+c-b))	51.8	50.7	50.6	50.5	50.8	-2.55%	-0.36%


対象週における各ケースのシステム全体の消費電力、残蓄熱量、二次供給温度を Fig. 7-9 から Fig. 7-13 に示す。消費電力が大きい時間帯は冷凍機が稼働している時間帯である。従来制御の 22 時蓄熱開始や 8 時蓄熱開始では、規則的に蓄熱がなされて蓄熱終了時に満蓄となるが、CADR の各ケースでは排出係数が小さい時間帯に蓄熱され、排出係数が大きい時間帯に放熱された。冷凍機が発停するときに二次送水温度の乱れがみられるが、温度が高い時間帯が放置されるといった状態は避けられていた。なお、二次送水温度を制御する放熱用熱交換器の一次側には流量を制御する弁が取り付けられていないため、冷凍機稼働時は冷凍機からの冷水が成り行きで流れてしまう。そのため、場合によっては一次側の流量過多により送水温度が 5°C 近くになってしまいが、この現象はシステムの構造上避けられないため不具合とはみなさないこととした (2.1.3.参照)。

CADR の各ケースでは、負荷予測において予測誤差がないと仮定した Case1.0 に対し、実際よりも小さく予測する Case0.9 では残蓄熱量が小さい傾向が得られた。残蓄熱量が小さくなる方が蓄熱槽を最大限利用することになり、排出係数に応じたより柔軟な蓄放熱制御が行われるはずであるが、Case0.9 では 6 月 8 日未明に残蓄熱量がほぼ 0 となっており、それに伴い冷水供給温度も上昇した。しかし、冷水供給温度が上昇後ただちに冷凍機が稼働したため、供給温度が上昇していた時間は短く抑えられた。対象期間における CO₂ 排出量は Case0.9 の方が Case1.0 よりも小さかったが、本件を鑑みると Case1.0 の時により適切な制御がなされたとみなすことができる。


また、負荷を実際よりも大きく予測する Case1.1 は Case1.0 に対して残蓄熱量が大きい傾向が得られた。予測期間において、より放熱が必要だと MPC において判断されたためである。Case0.9 とは反対に蓄熱槽の容量が疑似的に減少することで蓄放熱運転の自由度が低下し、CO₂ 排出量は増加してしまったと考えられる。しかし依然として 8 時に蓄熱を開始するケースに対して CO₂ 排出量は削減傾向にあったため本手法は 10%の負荷予測誤差に対しても有効であることがわかった。



(a) Power and coefficient




(b) Amount of residual heat in storage tanks




(c) Supply chilled water temperature


Fig. 7-9 Results (Conventional, storage from 22:00)



(a) Power and coefficient




(b) Amount of residual heat in storage tanks




(c) Supply chilled water temperature


Fig. 7-10 Results (storage from 8:00)



(a) Power and coefficient




(b) Amount of residual heat in storage tanks




(c) Supply chilled water temperature


Fig. 7-11 Results (CADR, Case0.9)



(a) Power and coefficient




(b) Amount of residual heat in storage tanks




(c) Supply chilled water temperature


Fig. 7-12 Results (CADR, Case1.0)



(a) Power and coefficient



(b) Amount of residual heat in storage tanks



(c) Supply chilled water temperature

Fig. 7-13 Results (CADR, Case1.1)

7.6. 考察と今後の課題

計算結果より、提案する CADR は 10% の負荷予測誤差に対しても CO₂ 排出量の削減効果を得られることが示された。ただし、負荷予測が実際よりも小さい方向に誤差を有した場合、残蓄熱量不足による供給温度の上昇が生じた。本検討では残蓄熱量不足により温度が上昇した後、ただちに冷凍機が稼働したため、温度が上昇していた時間帯は短かった。しかし、供給温度上昇を極力避けたいシステムの場合は、残蓄熱量が小さい時に予測負荷を大きく見積もるといった工夫が必要であると考えられる。

本章では MPC による低炭素制御の効果を定量化することを目的としたが、本手法の実装にあたっては予測負荷の逐次的な補正といったモデルの入力値の精度向上と、シミュレーション内の機器モデルを実際の機器挙動に近づけるという意味でのモデル自体の精度向上が必要になると考えられる。

本検討で対象とした 6 月上旬は夏季の最盛期ではないため負荷は比較的大きくない。その一方で 6 月の排出係数の変動は 7, 8, 9 月といった夏季に対して大きい (Fig. 7-1 参照)。蓄熱槽が 2 日分の負荷をほぼ賄えるため、対象週は蓄熱槽を最大限活用できる期間だといえる。これ以上負荷が大きくなると蓄熱槽の容量が不足し、排出係数が大きい時間帯に冷凍機を稼働させる必要が生じる。また、排出係数の変動がそもそも小さいと本手法による CO₂ 排出量削減効果も小さくなってしまう。そのため本手法による年間の低炭素効果を適切に評価するためには年間または季節ごとの計算が必要である。

調整力の大きさが低炭素化の大きな要因であることがわかったため、調整力を蓄熱槽のみならず蓄電池や躯体蓄熱にも拡大し、建物全体としての低炭素効果のポテンシャルを算出することが今後の課題である。そのためには、モデル化の範囲を本検討における熱源システムから空気側を含めた空調システム全体さらには躯体までに広げる必要がある。さらに、居住者の温冷感も考慮した室温制御を行うことで、居住者の温冷満足度を妨げることもない低炭素制御が実現されることが考えられる。

本検討は一つの建物を対象としたものである。本提案手法が電力系統内で大規模に適用された場合に再生可能エネルギーの導入量がどの程度拡大するか推定することも今後の課題である。

なお、本章で検討した手法に対し、目的関数を電力価格とすることで電力価格設定による DR への対応が可能となる。将来的には再生可能エネルギーの単価低下により動的 CO₂ 排出係数と電力価格は比例関係になることが予想されるため、本手法の電力価格に基づいた制御への応用も期待される。

7.7. 小括

本章では、蓄熱槽を調整力として有する事務所 A の熱源システムを対象に、モデル予測制御を用いた低炭素制御に関する検討を行い、以下の知見を得た。

①動的 CO₂ 排出係数の推定

太陽光発電など再生可能エネルギーは時刻ごとに出力が変動する。そのため本質的に電力量当たりの二酸化炭素排出量は時刻ごとに異なる。そこで系統における 1 時間ごとの発電量当たりの二酸化炭素排出量を推定し、需要家側による低炭素な電力利用の基礎情報を得た。

②モデル予測制御による低炭素制御

排出係数の小さい電力を有効に利用するには、エネルギーを効果的に貯めることが必要である。そこで負荷予測と動的 CO₂ 排出係数を入力値として、予測期間における CO₂ 排出量を最小化する制御を実行するモデル予測制御 (MPC) をシミュレーションに組み込み、6 月の 1 週間を対象にその効果を試算した。その結果、22:00 に蓄熱を開始する夜間蓄熱に対し、MPC は約 47% の削減効果を得られた。8:00 に蓄熱を開始する昼間蓄熱に対しても約 13% の削減効果を得られた。また、10% の負荷予測誤差に対しても本手法は CO₂ 排出量削減の観点から有効であった。

蓄電池や躯体蓄熱といった調整力の拡大や、系統全体へ本手法が普及した場合の再生可能エネルギー導入拡大量の推定は今後の課題である。

Acknowledgements

本章の検討は，日立東大ラボ「ハビタット・イノベーション」プロジェクト（Hitachi-U Tokyo Laboratory ‘Habitat Innovation’ Project），JSPS Research Fellow, Grant number JP17J08140 の支援を受けて遂行された。

参考文献

- [1] Obi Manasseh, Bass Robert : Trends and challenges of grid-connected photovoltaic systems – A review, Renewable and Sustainable Energy Reviews, Vol. 58, pp.1082-1094, 2016.
- [2] 九電 きょう太陽光制御，日本経済新聞，2018 年 10 月 13 日．
- [3] Braun James E. : Reducing energy costs and peak electrical demand through optimal control of building thermal storage, ASHRAE Transactions, Vol. 96, No. 2, pp.876-888, 1990.
- [4] Albadi Mohamed H., El-Saadany Ehab F. : Demand response in electricity markets: An overview, 2007 IEEE Power Engineering Society General Meeting, pp.1-5, 2007.
- [5] US Department of Energy : Benefits of demand response in electricity markets and recommendations for achieving them, 2006.
- [6] 資源エネルギー庁：エネルギー・リソース・アグリゲーション・ビジネスに関するガイドライン，資源エネルギー庁，2017.
- [7] Siano Pierluigi : Demand response and smart grids—A survey, Renewable and Sustainable Energy Reviews, Vol. 30, pp.461-478, 2014.
- [8] Kiliccote Sila, Piette Mary Ann, Hansen David : Advanced controls and communications for demand response and energy efficiency in commercial buildings, Second Carnegie Mellon Conference in Electric Power Systems, 2006.
- [9] Hao He, Corbin Charles D., Kalsi Karanjit, Pratt Robert G. : Transactive control of commercial buildings for demand response, IEEE Transactions on Power Systems, Vol. 32, No. 1, pp.774-783, 2016.
- [10] 卸市場急拡大でも青息吐息——新電力、「寄らば大樹」鮮明、価格なお不安定、大手頼みに（真相深層），日本経済新聞，2019 年 3 月 13 日．
- [11] Zhao Yang, Lu Yuehong, Yan Chengchu, Wang Shengwei : MPC-based optimal scheduling of grid-connected low energy buildings with thermal energy storages, Energy and Buildings, Vol. 86, pp.415-426, 2015.

- [12] 九州電力 HP : 系統情報の公開, http://www.kyuden.co.jp/wheeling_disclosure.html (2019 年 10 月 17 日閲覧)
- [13] 今村栄一, 井内正直, 坂東茂 : 日本における発電技術のライフサイクル CO₂ 排出量総合評価, 電力中央研究所報告.総合報告.電力中央研究所 編, 第 6 号, pp.6, 2016.
- [14] 九州電力 HP : 火力発電所紹介, http://www.kyuden.co.jp/effort_thirmal_k_hatsuden_index.html (2019 年 9 月 27 日閲覧)
- [15] Garcia Carlos E., Prett David M., Morari Manfred : Model predictive control: theory and practice—a survey, *Automatica*, Vol. 25, No. 3, pp.335-348, 1989.
- [16] Garcia Carlos E., Morari Manfred : Internal model control. A unifying review and some new results, *Industrial & Engineering Chemistry Process Design and Development*, Vol. 21, No. 2, pp.308-323, 1982.
- [17] Morari Manfred, H. Lee Jay : Model predictive control: past, present and future, *Computers & Chemical Engineering*, Vol. 23, No. 4, pp.667-682, 1999.
- [18] Afram Abdul, Janabi-Sharifi Farrokh : Theory and applications of HVAC control systems – A review of model predictive control (MPC), *Building and Environment*, Vol. 72, pp.343-355, 2014.
- [19] Garriga Jorge L., Soroush Masoud : Model predictive control tuning methods: A review, *Industrial & Engineering Chemistry Research*, Vol. 49, No. 8, pp.3505-3515, 2010.
- [20] Kanarachos A., Geramanis K. : Multivariable control of single zone hydronic heating systems with neural networks, *Energy Conversion and Management*, Vol. 39, No. 13, pp.1317-1336, 1998.
- [21] Thomas Bertil, Soleimani-Mohseni Mohsen : Artificial neural network models for indoor temperature prediction: investigations in two buildings, *Neural Computing and Applications*, Vol. 16, No. 1, pp.81-89, 2007.
- [22] Afram Abdul, Janabi-Sharifi Farrokh, Fung Alan S., Raahemifar Kaamran : Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system, *Energy and Buildings*, Vol. 141, pp.96-113, 2017.
- [23] Zhou Qiang, Wang Shengwei, Xu Xinhua, Xiao Fu : A grey-box model of next-day building thermal load prediction for energy-efficient control, *International Journal of Energy Research*, Vol. 32, No. 15, pp.1418-1431, 2008.

- [24] Powell Kody M., Sriprasad Akshay, Cole Wesley J., Edgar Thomas F. : Heating, cooling, and electrical load forecasting for a large-scale district energy system, *Energy*, 74, pp.877-885, 2014.
- [25] Zhao Jing, Liu Xiaojuan : A hybrid method of dynamic cooling and heating load forecasting for office buildings based on artificial intelligence and regression analysis, *Energy and Buildings*, Vol. 174, pp.293-308, 2018.
- [26] Fan Cheng, Xiao Fu, Zhao Yang : A short-term building cooling load prediction method using deep learning algorithms, *Applied Energy*, Vol. 195, pp.222-233, 2017.
- [27] Eberhart Russell, Kennedy James : A new optimizer using particle swarm theory, MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science, pp.39-43, 1995.
- [28] Yang Xin-She : Nature-inspired metaheuristic algorithms, Luniver press, 2010.
- [29] Asavanant Warit, Shiozawa Yu, Yokoyama Shota, Charoensombutamon Baramee, Emura Hiroki, Alexander Rafael N., Takeda Shuntaro, Yoshikawa Jun-ichi, Menicucci Nicolas C., Yonezawa Hidehiro : Generation of time-domain-multiplexed two-dimensional cluster state, *Science*, Vol. 366, No. 6463, pp.373-376, 2019.
- [30] Arute Frank, Arya Kunal, Babbush Ryan, Bacon Dave, Bardin Joseph C., Barends Rami, Biswas Rupak, Boixo Sergio, Brandao, Fernando G. S. L., Buell David A., Burkett Brian, Chen Yu, Chen Zijun, Chiaro Ben, Collins Roberto, Courtney William, Dunsworth Andrew, Farhi Edward, Foxen Brooks, Fowler Austin, Gidney Craig, Giustina Marissa, Graff Rob, Guerin Keith, Habegger Steve, Harrigan Matthew P., Hartmann Michael J., Ho Alan, Hoffmann Markus, Huang Trent, Humble Travis S., Isakov Sergei V., Jeffrey Evan, Jiang Zhang, Kafri Dvir, Kchedzhi Kostyantyn, Kelly Julian, Klimov Paul V., Knysh Sergey, Korotkov Alexander, Kostritsa Fedor, Landhuis David, Lindmark Mike, Lucero Erik, Lyakh Dmitry, Mandrà Salvatore, McClean Jarrod R., McEwen Matthew, Megrant Anthony, Mi Xiao, Michielsen Kristel, Mohseni Masoud, Mutus Josh, Naaman Ofer, Neeley Matthew, Neill Charles, Niu Murphy Yuezhen, Ostby Eric, Petukhov Andre, Platt John C., Quintana Chris, Rieffel Eleanor G., Roushan Pedram, Rubin Nicholas C., Sank Daniel, Satzinger Kevin J., Smelyanskiy Vadim, Sung Kevin J., Trevithick Matthew D., Vainsencher Amit, Villalonga Benjamin, White Theodore, Yao Z. J., Yeh Ping, Zalcman Adam, Neven Hartmut, Martinis John M. : Quantum supremacy using a programmable superconducting processor, *Nature*, Vol. 574, No. 7779, pp.505-510, 2019.

本章に関連する発表論文

[国際会議・査読有・口頭]

1. Shohei MIYATA, Yasuhiro KUWAHARA, Yasunori AKASHI, Jongyeon LIM, Weijie ZHANG, Naoki YOSHIMOTO, Model Predictive Control of Chillers with Heat Storage Tanks as a Carbon Activated Demand Response, The 2nd International Conference of IASUR, VII-3, Xi'an China, March 2019

第8章

総論

8.1. 本研究で得られた成果

熱源システムの性能を最大限引き出す次世代 BEMS の実現に向けて、不具合検知・診断と最適化に関して、本研究で対象とした課題とその成果を挙げる。

I. 次世代 BEMS の提案

従来の BEMS はその機能としてデータの収集・蓄積や月間値のグラフ化・可視化などを行う。しかしシステムで生じている不具合を検知・診断してさらに最適制御を行う機能は有しておらず、BEMS の活用には手作業によるデータ分析が必要である。データ分析には高度な知識と技能が必要であるため、従来の BEMS のみではシステムの運用を改善することは難しかった。

そこで本研究ではまず蓄積された生データを整理し、欠損値や異常値を処理するデータクレンジング、不具合検知・診断、最適制御、そして検知・診断された不具合を修復する保全計画の立案の機能を有する BEMS を次世代 BEMS と称し、この内不具合検知・診断と最適制御に関する検討を行うことを本論の目的とした。

II. 手作業の BEMS データ分析による性能把握・不具合診断

事務所 A と工場 B に設置されている空調用熱源システムにおいて収集されている BEMS データを手作業により分析した。各システムの性能を把握し、性能が発揮できていない部分について性能発揮を妨げる要因である不具合を診断した。対象とした両システムにおいて機器性能低下、設定値不全、下限値不全といった不具合が原因とみられる挙動がみられた。これらを診断するためには、機器特性や物理式に基づいた性能指標の算出や、制御ロジックに基づいた適切な制御状態の想定が必要であることを示した。

III. シミュレーションプログラムの構築

不具合検知・診断や最適制御には、不具合が生じている場合や設定値が変更された場合の機器制御や温度・流量といったシステム挙動の算出が必要である。そのため、負荷や外気湿球温度といった境界条件に対するシステム挙動を適切に表現可能なシミュレーションプログラムを構築した。具体的には、機器性能曲線、熱交換機や流量計算に関する物理モデル、PI 制御等のフィードバック制御を組み込んだシミュレーションプログラムを作成し、制御の過渡状態を算出可能とした。

IV. 不具合検知・診断スキームの提案

熱源システムにおける不具合を適切に検知・診断して活用するために以下のスキームを提案した。まず、対象システムにおける不具合の有無そのものを検知し、次にどの種類の不具合が生じているかを診断し、最後に診断された不具合の程度を同定することで不具合の修復効果を定量化する。このスキームの結果に従うことで、不具合を適切に取り除くことが

可能になると考えられる。本研究では検知・診断・同定のうち、不具合の検知と検知・診断を検討対象とした。

V. 性能分布の算出による不具合検知

熱源システムではセンサや制御量に真値とのずれが生じうる。そこで、シミュレーションにそのずれを不確かさとして組み込むことで、不確かさによる SCOP 分布（性能分布）を算出した。この性能分布の信頼区間外、性能が低い側に BEMS データが位置した場合、対象システムにおいて SCOP に大きな影響を与える不具合が存在すると判断できる。多くのシステムを同時に管理する際、本手法によって重大な不具合が生じているシステムから優先的に対応することが可能になることが期待される。

VI. 深層学習を用いた不具合検知・診断

本研究において不具合検知・診断は、BEMS データがどの不具合データに近いかを判断する分類問題と捉えた。まず、シミュレーションプログラムに様々な不具合条件を与え、その計算結果を不具合データベースとした。次に深層学習の一手法である畳み込みニューラルネットワークに不具合データベースを与え、不具合の特徴を学習させた。そして、BEMS データを学習済みネットワークに入力することで、BEMS データがシミュレーションで想定したどの不具合の特徴がみられるか診断可能とした。本手法は不具合の想定とシミュレーションの実行という労力が必要であるが、人がデータを詳細に分析する必要がなくなるという点で有用だと想定される。

VII. モデル予測制御による低炭素制御

再生可能エネルギーが普及するにつれて、デマンドレスポンスなど電力系統を考慮した需要家側の制御が必要となってきた。そこで、時刻別の CO₂ 排出係数[kg-CO₂/kWh]を推定し、これに基づく機器制御を行った。蓄熱槽を調整力として有する事務所 A の熱源システムを対象とし、冷凍機の発停をモデル予測制御によって決定した。その結果、計算対象期間とした 6 月の 1 週間において、従来の夜間蓄熱・昼間蓄熱に対してそれぞれ 47%、13%の二酸化炭素排出量削減効果が得られた。また、予測負荷の誤差に対しても削減の効果は得られたため、本手法は有効であることが示された。

8.2. 本研究の課題と展望

前節に従ってそれぞれの課題と展望を以下に記述する。

I. 次世代 BEMS の提案

次世代 BEMS として提案した機能は、本研究で検討した不具合検知・診断と最適制御に加えてにデータクレンジングと保全計画の立案がある。本研究ではまず手作業によるデータ分析を行ったが、その際に項目名とデータの値が一致するかといった確認や欠損データの把握も併せて行った。特に不具合検知・診断は入力されるデータの質が悪いと適切に実行できなくなってしまうため、BEMS データのクレンジングは非常に重要な課題である。データクレンジングには異常値の除去も含まれるが、データ収集の際に生じた異常値なのか、不具合の結果として得られた異常値なのか判別する技術も開発する必要がある。そのため、データクレンジングは不具合検知・診断と表裏一体の側面もある。データクレンジング手法を開発するためには多くのデータを手作業で分析し、クレンジングが必要な様々な事象を蓄積する必要がある。今後より多くのシステムを対象として不具合検知・診断を行う中で適切なデータクレンジング手法を開発する予定である。また、そもそもシステム挙動を把握するためには各機器の流量，出入口温度，消費電力のデータが必要である。BEMS データポイントの設計時には、これらポイントがそろっていることを確認する必要がある。

III. シミュレーションプログラムの構築

本研究では熱源システムを対象としたが、モデル化の範囲を拡大して空気側を含む空調システム全体を対象とすることが大きな課題である。Air Handling Unit (AHU)や Variable Volume (VAV)システムは不具合が多く生じる部分であるが、本研究で検討した深層学習の適用はまだなされておらず、その有効性が検証されることが望ましい。

空調システム全体にモデル化の範囲を拡充することで、最適制御に関してもさらなる検討が可能になる。本研究で提案した低炭素制御は調整力が必要であったが、調整力を有さないシステムであっても室温制御や躯体蓄熱によって負荷を制御することが可能となる。この時、居住者個人の温冷感特性を考慮することで快適性を損なわない負荷制御の検討が可能となるはずである。

本研究で構築したシミュレーションプログラムは、制御の過渡状態を表現できる準動的モデルである。熱交換器や蓄熱槽モデルに加え、PI 制御等のフィードバック制御は動的モデルであるが、冷凍機やポンプは前時刻の値を利用しない（微分項を有さない）静的モデルであった。そのため、機器の立ち上がり時の特性が現実とは異なる可能性が残っている。特に、デマンドレスポンスでは冷凍機の立ち上がりの起動、室温制御の時間遅れが検討項目として挙げられるため、シミュレーションプログラム内の各モデルを全て動的にモデル化することは今後必要になると考えられる。

また、流量計算の連立方程式の立式や制御モデルの記述には労力を要する。そのため、プログラム構築を省力化するための技術開発も今後の課題として挙げられる。

IV. 不具合検知・診断スキームの提案

本研究で提案した不具合検知・診断スキームは、不具合をまず検知し、次に種類を診断し、最後にその程度を同定するものであった。本研究では不具合の検知・診断を対象としたため、程度の同定にはまだ取り組めていない。本研究を通し、熱源システムは複数の不具合を同時に有することがわかったため、どの不具合から優先的に修繕すべきか判断することは必要になると考えられる。そのため、不具合の程度を同定し、修繕した際の効果を定量化して比較することで保全計画の立案が可能になると考えられる。

V. 性能分布の算出による不具合検知

本検討では不確かさを考慮した性能分布によって不具合検知が可能となるフレームワークを示したが、不確かさが真の値に対して正規分布で生じること、その正規分布のパラメータは機器精度に起因することという仮定を置いている。これらの仮定の確からしさを高めるためには、機器メーカーや現場でのセンサ設置の状況、BEMS のデータ収集システムの特性のさらなる把握が必要である。これらを踏まえたうえで、熱源システムのみならず空調システム全体における性能分布の算出が今後の課題である。

VI. 深層学習を用いた不具合検知・診断

分類問題としての不具合検知・診断は適切な不具合データベースの作成が最も重要である。本検討では 1 年間や 4 か月といった長期間の負荷条件のもとでのシミュレーション結果を不具合データベースとしたが、不具合データベースの計算そのものや畳み込みニューラルネットワークの学習に時間を要した。本手法は一日に一回診断を行うことが可能であるため、学習期間の設定や転移学習等を活用した効率的な学習による実装実現性の向上が今後の課題である。また、本手法を他システムに適用するにあたり、不具合種類を想定するフレームワークの作成が必要である。対象システムの構成から生じうる不具合を容易に設定できるようにすることで、不具合データベース作成の一助となるためである。

VII. モデル予測制御による低炭素制御

本検討では冷凍機の発停のみを最適化の変数とした。冷凍機の発停に加え、冷却水温度制御の設定値も変数とすることでさらなる効率向上を目指すことができると考えられる。また、調整力も蓄熱槽のみであったため、蓄電池や室側の設定温度・躯体蓄熱も考慮することで低炭素効果の向上が期待される。

また、今回は建物単体を対象としたが、将来的に本制御手法が電力系統全体に普及した場合、再生可能エネルギーによる出力変動を吸収することにつながる考えられる。その

ため、本手法が普及することによる再生可能エネルギーの導入拡大量の推定も今後の課題である。

本研究における成果が次世代 BEMS として実装されることで、従来では居住者からクレームが来ない限り不具合が放置されていた熱源システムにおいて、不具合検知・診断によりエネルギー効率が向上するとともに、今後柔軟なエネルギー利用が求められる中でシステムのポテンシャルを最大限引き出す制御が可能となる。シミュレーションプログラム作成の省力化やデータクレンジング・保全計画の立案など、さらなる技術開発が実装・普及には必要と考えられるが、本研究の成果が低炭素化社会実現への礎となることが期待される。

謝辞

本論文は、筆者が2014年4月に東京大学工学部建築学科赤司研究室に卒論生として配属されて以降、修士・博士後期課程において遂行した研究のうち、熱源システムの不具合検知・診断と最適化に関する取り組みをまとめたものである。

各章の末尾にも記載したが、まず本論文に関連する金銭的な支援を列挙する。筆者は博士後期課程の3年間、日本学術振興会特別研究員DC1（JP17J08140）として研究に従事した。また、不具合検知・診断に関しては日本学術振興会科研費（JP18K13879）に加え、東京電力ホールディングス株式会社との共同研究の成果である。最適制御に関しては日立東大ラボ「ハビタット・イノベーション」プロジェクト（株式会社 日立製作所との共同研究）における成果である。

最後にこれまでの研究活動に対しご指導・ご支援いただいた方々に謝意を表し、本論文の結びとしたい。

東京大学教授 赤司泰義先生には、卒業論文執筆から6年間にわたり指導教官として多大なるご指導をいただきました。先生の卓越した長期的な視座のもと、本博士論文につながる研究テーマに出会い、紹介いただいた素晴らしい研究者・実務者の方々に囲まれ、設備的にも恵まれた環境で思う存分研究に取り組むことができました。具体的な研究手法から研究さらには大学の在り方まで、ゼミやその他日常的な議論の場において多くのことを学ぶことができました。また、国際会議や国際ワークショップ等、多くの機会を与えてくださったことも感謝いたします。

東京大学教授 大岡龍三先生には、副査として年2回指導いただきました。不確かさの定義について多くのコメントをいただき、非常に参考になりました。また、最適制御についても的確なコメントをいただきました。

名古屋大学教授 田中英紀先生には、副査として予備審査から指導いただきました。建築設備の運用に関する豊富な経験に基づいた的確なご指摘を多くいただきました。本研究成果の実装に向けても参考になるご意見をいただきました。

東京大学准教授 前真之先生には、卒業論文時から環境系ゼミにて多くのコメントをいただき、また副査として指導いただきました。設計者や利用者の立場を踏まえたご指摘により、研究成果の使われ方をより明確に考えることができました。

東京大学講師 菊本英紀先生には、副査として指導いただきました。モデル化に関して、空調システムのシミュレーションプログラムを構築・利用するうえで常に考えるべき鋭い指摘をいただきました。

江原大学校助教 林鍾衍先生には、修士から博士にかけて、約4年間にわたり赤司研究室の助教として多くの指導をいただきました。本博士論文の内容全てについて多くのご指摘をいただきました。特に研究手法や論文構成についての的確なご指摘をいただきました。

東京大学 赤司研究室の皆様には、同期・後輩全員から様々な刺激をいただきました。特に博士後期課程に進学後、熱源システムに関する研究を共に取り組んでくれた方々からは大きな刺激をいただきました。

父・博司，母・万喜子は，博士後期課程進学を快諾してくれたことに加え，研究に集中できる環境を与えてくれました。また，兄・陽司や長年私を支えてくれた小枝優佳里氏，また同期の友人たちは常に私を応援してくれ，精神的な支えとなりました。3年間の博士後期課程での研究生活が日々充実したのは皆様のおかげです。深く感謝の意を示します。

皆様のご支援・ご指導の成果として執筆した本博士論文を一つのステップとして，建築環境工学を基礎に持続可能な社会の実現に貢献してまいりたいと思います。

