

博士論文

(題目)

機械学習モデルを用いた設備 電力需要制御に関する研究

岐阜大学大学院工学研究科
電子情報システム工学専攻

氏名：鈴木 啓太

指導教員：堀川 忠三

目次

第1章 序論	1
1.1 本研究の背景	1
1.2 本研究の課題と従来研究	4
1.3 本研究の目的	6
1.4 本研究の実施事項	7
第2章 設備電力需要制御システムと機械学習モデル	9
2.1 緒言	9
2.2 スマートグリッド	10
2.3 高速自動デマンドレスポンス（FastADR）	10
2.4 デマンドレスポンスの実現方式	12
2.5 ビルマルチ空調機設備とアグリゲーション	14
2.5.1 ビル空調システムとデマンドレスポンス	14
2.5.2 ビルマルチ空調設備	14
2.5.3 ビルマルチ空調機設備とアグリゲーション	15
2.6 設備電力需要制御システム	18
2.6.1 RTP 設備電力適応制御システム	19
2.7 ビルマルチ空調機設備の機械学習予測モデル	21
2.7.1 ニューラルネットワーク（NN）モデル	22
2.8 設備電力需要制御システムの制御	24
2.9 設備電力需要制御システムと応答時間	24
2.10 結言	25
第3章 設備電力需要制御モデルの機械学習	26
3.1 緒言	26
3.2 平常運転からの機械学習訓練データ抽出	27
3.2.1 専用試験によるデータ収集	27
3.2.2 平常運転データと電力制限指令	27
3.2.3 Breakpoint 訓練データ収集方式	28
3.2.4 仮想電力制限指令の提案	32
3.3 機械学習訓練データ収集とニューラルネットワークモデルの構築	34
3.4 RTP 適応制御シミュレーション実験	36
3.4.1 ビルマルチ空調設備モデル	36
3.4.2 シミュレーション実験条件	36
3.5 応用サービス上の性能比較	40
3.6 応用サービス上の有用性	43
3.7 結言	45

第4章 機械学習モデルの予測誤差集約均し効果	4 6
4.1 緒言	4 6
4.2 FastADR 機械学習モデル予測誤差の均し効果	4 7
4.2.1 FastADR 機械学習モデル予測誤差	4 7
4.2.2 予測誤差の定義	4 8
4.2.3 予測誤差における均し効果	4 8
4.3 結言	5 0
第5章 機械学習モデルの設備多様性	5 1
5.1 緒言	5 1
5.2 エミュレーションシステム	5 3
5.2.1 ビルマルチ空調機エミュレータ	5 3
5.2.2 仮想ビルエミュレータ	5 4
5.3 仮想ビル群の多様性モデリング	5 6
5.3.1 仮想ビルの多様性モデル化	5 6
5.3.2 FastADR 離脱条件の多様性モデル化	5 7
5.4 エミュレーション実験	5 8
5.4.1 ビル全体消費電力の定義	5 8
5.4.2 FastADR アグリゲーション実験	5 8
5.5 結言	6 1
第6章 設備電力需要制御の制御残差集約均し効果	6 2
6.1 緒言	6 2
6.2 FastADR 重ね合せ実験	6 3
6.2.1 応答時系列データ収集方式	6 3
6.2.2 応答時系列データ収集実験	6 5
6.2.3 FastADR 応答の繰り返し重ね合せ集計結果	6 5
6.3 FastADR 組合せアグリゲーション推定	6 7
6.3.1 FastADR 組合せアグリゲーション推定	6 7
6.3.2 LNG 火力 EDC モードとの応動速度比較	6 9
6.4 アグリゲーション予測誤差と制御残差	7 0
6.5 結言	7 1
第7章 結論	7 2
謝辞	7 3
論文目録	7 4
付録	7 7
付録 A Breakpoint アルゴリズム	7 8
A.1 Breakpoint アルゴリズムの概要	7 8
付録 B 大量アグリゲーション時の統計理論の検討	8 0
B.1 中心極限定理の考察	8 0
B.2 エルゴート性の考察	8 1

付録 C FastADR 応答の重ね合せ時系列の探索.....	8 2
C. 1 重ね合せ時系列の探索プログラム	8 2
付録 D 仮想ビルの多様性モデリング定義.....	8 9
D. 1 BEM1.1 型（中型オフィスビル型）のビルクラス定義.....	8 9
D. 2 FastADR 離脱条件 定義.....	9 0
付録 E 設備電力需要応答システム全体の通信.....	9 3
E. 1 緒言	9 3
E. 2 ADR クラウドアグリゲーション	9 5
E. 2. 1 OpenADR システム設計	9 5
E. 2. 2 IEEE1888 の利用	9 5
E. 3 ビルマルチ空調設備.....	9 6
E. 3. 1 ビルマルチ空調設備における電力量計	9 6
E. 3. 2 ビルマルチ空調設備における制御構造	9 6
E. 4 電力削減モデル.....	9 7
E. 4. 1 実際のビル電力時系列データの計測	9 7
E. 4. 2 電力削減遅延モデルの作成.....	9 8
E. 5 アグリゲーション通信試験	9 9
E. 5. 1 ADR アグリゲーション通信の実装	9 9
E. 5. 2 ADR アグリゲーション通信試験の結果.....	1 0 0
E. 6 考察	1 0 2
E. 7 結言	1 0 3
参考文献	1 0 4

第1章 序論

1.1 本研究の背景

人類の持続可能な発展にあたり、地球温暖化への取り組みは重要である[1]。2020年に菅首相が所信表明において2050年までに全体としてゼロにする脱炭素社会の実現を目指す[2]と宣言した。

この脱炭素社会の実現においては、エネルギー需要の削減と再生可能エネルギーの導入の2点が重要といわれる[3]。再生可能エネルギーのうち、太陽光発電や風力発電等の自然エネルギーは気象条件によって発電量が大幅に変動する[4]-[8]。例えば、太陽光発電であれば、日中は発電量が多い一方、日没後の発電量はゼロとなる。ゆえに太陽光発電の増加に伴い「ダックカーブ現象」[9][10]と呼ばれる、系統に対して日中は需要を超える電力が供給される余剰電力の問題と、夕方の需要ピークと太陽光の出力低下が重なり供給不足となる問題が発生するようになっている。

加えて、太陽光発電は分散型エネルギーとも呼ばれ、需要家側にも設置可能な特徴がある。そのため、従来は発電側から需要側へ一方的に電力が流れていたが、需要側から系統（発電側）の逆方向にも流れる（逆潮流）ようになる[11]-[14]。この発電量の変動と逆潮流の影響により、従来のように発電側だけでおこなう電力系統の瞬時需給バランスの維持は難しくなりつつある[15]-[17]。

瞬時需給バランスを維持するための電源を「調整力」と呼ぶ[18]。この調整力を提供しているのは主に火力発電である[19][20]。燃料の調整により発電量の調整が容易なことと、発電機の持つ慣性力により周波数の変化速度を緩和ができることがその理由である。しかし、再生可能エネルギーによる発電量の増大により稼働率は減少する傾向にあり、我が国でも2015年から2019年にかけて15%程度減少している[21]。さらに稼働率が低下したことで採算性が低下している火力発電は、電力自由化に伴いコスト競争が激しくなった影響で、新設の減少や既設の廃止・休止が加速する懸念もある[22]。

そこで、需要側の消費電力を能動的に制御することで同等の調整力を得ようとするデマンドレスポンス（需要応答）[23][24]と呼ばれる仕組みが始まっている。デマンドレスポンスは、自発的に需要側の負荷設備や発電設備を制御させ、仮想的に発電所のように機能させる。これらICTにより機械的におこなうものを自動デマンドレスポンスといい、特に分単位／秒単位で自動応答するものは、FastADR（高速自動デマンドレスポンス）と呼ばれる[1]。

この制御対象には蓄電池、照明等様々なものが検討・利用されているが、ビル空調システムは、ビルエネルギー管理システム（BEMS）で集中管理されていることが多く、さらにビル全体の合計電力の4割を占める[25]といわれていることから、デマンドレスポンスの対象として有用である。

本研究では、ビル空調システムの中でもビルマルチ空調機を対象としたデマンドレスポンスを研究対象とする。その理由はインバータ駆動負荷のこまやかな制御が可能[1]であること、そして台数規模である。我が国におけるビルマルチ空調機の設置台数を日本冷凍空調工業会の集計[29]を基に推定すると約152万台程度あり、仮に1台当たりの定格消費電力を10kWと仮定すると15GWオーダーの規模があるといえる[1]。

デマンドレスポンスの方式は「ネガワット取引方式」と「リアルタイム電力料金(RTP)方式」の2つに大きく分けられる。ビルマルチ空調機設備を用いる場合、どちらの方式でもデマンドレスポンスに対する空調機応答を予測するモデルは重要である。

「ネガワット取引方式」は、節電量に応じた報酬を支払うことで直接電力を削減する方式である。デマンドレスポンス参加者は、削減要求量からの一定幅以内の維持のための制御・削減可能電力量の見積もりに空調機応答の予測モデルを用いることが出来る。

「リアルタイム電力料金(RTP)方式」は、ピーク時に電力単価を高価に設定することで間接的に電力を削減する方式である。この方式でデマンドレスポンス参加者の利益を最大化するには、高価な時間帯に電力を抑制して安価な時間に室温を下げるような、料金と室温快適性のバランスの取れた空調スケジュールを計画する必要がある。この空調スケジュールを機械的に探索する場合、各スケジュールプランについて空調機の電力応答・室温モデルにより電気料金を予測し、もっとも安価なプランを選択する形となる。

このようにビルマルチ空調機設備のデマンドレスポンスの応答予測モデルは重要であるが、この予測モデルの予測期間は数分～数十分程度の短時間で良い。その理由は、我が国の電力量評価時間単位が事前審査では5分、運用時は30分で検討されているため[30]である。

ビルマルチ空調機設備の短時間応答予測モデルの構築手段を考える。モデルの利用者、つまりデマンドレスポンスの参加事業者において、ビルマルチ空調機の複雑な組み込み制御は（自社開発の機種でない限り）ブラックボックスであり、その応答時系列には確率的・非線形的に見えるような応答が含まれる。このような応答はビルマルチ空調機の機種で決定されるものではなく、その設置ビルの構造や設置箇所、稼働状況等の多様な外部環境要因でも変わる。

ゆえに短時間空調機応答予測モデルの構築において、一次遅れのような単純な構造のモデルでは不確実性・非線形的な空調機応答の予測は十分でない。また、多数の空調機について单一の応答予測モデル化を当てはめることは、多様な要因の組み合わせにより決まる空調機応答の予測には適していない。

そこで本研究では、機械学習分野のニューラルネット（Neural Network: NN）をビルマルチ空調機設備の短時間応答予測モデルに用いることにした。NNを選択した理由は、非線形的な分野において良い結果を得られていると知られていること、訓練データ数が十分に揃うことが出来れば一定の精度が期待でき、大量のモデルの構築も機械的に対応できることの3点である。

また、機械学習分野は近年発展が著しく、機械学習モデルが今後さらなる良い成果を出すのではないかと期待できるため、その利用を前提に検討することは将来においても活用できるだろう。

ビルマルチ空調機設備を用いたデマンドレスポンスシステム（電力需要制御システム）における機械学習モデルを利用した場合の既存の研究は、次節に説明するようにシステム構築における課題の検討で不十分である。

ここまで述べた通り、我が国は2050年までに脱炭素社会の実現を目指すと宣言しており、その実現にはデマンドレスポンスの活用が重要になるだろう。その将来を想定し、機械学習モデルを利用したビルマルチ空調機設備電力需要システムにおいて、システム構築面での検討をおこなう研究は、その一助となるのではないかと考えている。

1.2 本研究の課題と従来研究

機械学習モデルを利用したビルマルチ空調機設備電力需要システムのシステム構築面での課題について 3 つの観点から検討する。

まず、ビルマルチ空調機械学習モデルを構築する場合の課題を考える。「ニューラルネットワークの重みパラメータの 10 倍以上が必要」という経験則[90]もあるように、機械学習モデルの学習には大量の訓練データが必要である。ビルマルチ空調機械学習予測モデルにおける訓練データは電力制限指令に対するステップ応答時系列であり、そのデータを得るために実機専用試験が必要である。こういった専用試験は、十分なデータ数を得るまでに時間がかかるうえに、試験による室温変動が発生するためビル居住者への負担が大きい。ゆえに実用化のためには、データ収集の短時間化と居住者負荷を低減する方法の検討が必要である。

訓練データ取得のための専用試験の代わりとなるデータ収集方式について検討したものが、蜷川らの先行研究 (2017)[39]である。蜷川らは居住者負荷低減のために平常運転時系列データから訓練データを抽出するアイデアを基に、DNA 遺伝子解析アルゴリズムを抽出方法として応用した。これは、DNA 遺伝子コピー数確率分布が急変する位置を特定する数理技術を、空調機の平常運転時系列から電力消費が急変する時点の抽出に応用したアプローチだったが、これで抽出できるステップ応答時系列には電力制限指令が存在しない問題があった。この課題について当該研究は十分な検討がなされていない。

一方、訓練データ取得のための専用試験による居住者負荷の低減について検討したものが、蜷川らの 2 つ目の先行研究 (2018) [38]である。この研究で、蜷川らは専用試験をおこなうものの大信号の電力制限指令を避け、小信号の電力制限指令のみ印加する Modulation 方式を提案した。この方式は、大信号による室温急上昇を回避することで居住者の負担低減は期待されるが、十分なデータ数を得るために時間がかかることは変わらない。また、大信号によるステップ応答は収集できないことも課題である。

次にビルマルチ空調機設備を、機械学習モデルによる電力需要制御システムに適用する場合の課題を考える。課題となるのは大きく次の 2 つが考えられる。

- ① 不確実性：複雑な冷媒回路の分散型組込み制御・空調のユーザ使用状況に起因する制御動作が BEMS やデマンドレスポンスシステム、サービスプロバイダーから見て確率的なものと見える。
- ② 消費電力規模：個々のビルマルチ空調機の消費電力が kW オーダーであるのに対し、送配電網協議会の資料[30]によると我が国の需給調整市場における最低入札量は 1MW と非常に乖離している。

これらの課題の解決策の一つに大量アグリゲーション（集積）がある。大量アグリゲーションは、消費電力規模の拡大と均し効果による不確実性の減少が期待されるものである。ビルマルチ空調機を対象としたアグリゲーションや均し効果を検討した研究は、本研究の基礎となった蜷川らの先行研究（2017）[70]の他に見当たらないが、気象による発電量の出力変動が大きい太陽光発電システムを対象にした事例はいくつか見つかる。柳川ら（2001）[16]は名古屋市の5地点における実測結果から、太陽光発電システムに必要となる日射量に基づくLFC容量について、分散導入による均し効果によってLFC容量が半分程度になると評価した。大関ら（2010）[31]は、関東・関西の半径100km圏内にそれぞれ13地点に分散配置した太陽光発電システムの実測から、年間を通じた統計的な変動特性の分析評価をおこない、単地点の3割低減の結果を得ている。

最後にビルマルチ空調機械学習モデルを用いた電力需要制御システムの課題を検討する。当該システムの制御に関する研究として、田丸ら（2013）[75]は外調機を加えたビルマルチ空調システムの省エネ制御手法を提案している。三宅ら（2013）[76]は、蓄電池を加えたビルマルチ空調システムについて運転計画を最適化する手法を提案している。いずれも時間単位の遅い制御の研究であり、本研究の対象とは一致しない。

また、現実的にはビルマルチ空調機には、さまざまな機種や建築設置条件、運転熱負荷等の多様な稼働条件が存在するはずであるが、従来の研究ではそういった面での検討は限定的であった。例えば、蜷川らの先行研究（2018）[37]では室内機に優先度を設定した場合において、RTP方式デマンドレスポンスにおける全館電気料金の最適化をおこなう予測制御方式を提案した。そのなかで、室外機10台のシミュレーションをおこなっているが、室外機の稼働条件は2種類しか記述されていない。

1.3 本研究の目的

本研究の主な目的は、ビルマルチ空調機械学習モデルによる電力需要制御システムにおけるシステム構築面での課題の検討をおこなうものである。

- ① ビルマルチ空調機械学習モデルを構築する場合における開発期間の短縮を目的に、その訓練データを専用試験無しに収集する方式を開発する。
- ② 機械学習モデルによるビルマルチ空調機設備電力需要制御システムにおいて、大規模アグリゲーションによる均し効果を評価するために、ビルマルチ空調機械学習モデルの予測誤差の均し効果を定量的に示す。
- ③ 設備電力需要制御システムにおいて空調機種や建築設置条件や運転熱負荷などの多様な条件を組合せた現実的なケースを考慮して、ビルマルチ空調機械学習モデルの訓練データの収集を目的とした、ビルマルチ空調機リアルタイムエミュレータの多様性の付与手法を開発する。

1.4 本研究の実施事項

本研究の実施事項を本文中の各章と対応させて以下に示す。

第2章では、本研究の対象について述べる。

第3章では、ビルマルチ空調機械学習モデルを構築する場合に必要となる訓練データについて、DNA解析アルゴリズムの転用により、専用試験無しに平常時の運転時系列データから収集する方式について述べ、従来方式との比較により、制御性・開発時間を評価する。

第4章では、機械学習モデルによる設備電力需要制御システムにおいて、アグリゲーション数に対する機械学習モデル予測と実応答との予測誤差について定量的な評価をおこなう。

第5章では、設備電力需要制御システムにおいて、空調機種や建築設置条件や運転熱負荷などの多様な条件を組合せた現実的なシナリオを、先行研究で開発されたエミュレータに適応する方法について述べ、その多様性を2つの時間帯で確認する。

第6章は、本研究の主目的とはやや外れるものの設備電力需要制御システムの構築にあたり課題となる、大規模アグリゲーション時の制御残差における均し効果について評価をおこなう。

第7章では、本研究の成果を総括する。

本研究の目的と実施事項を、研究対象であるビルマルチ空調機械学習モデルによる電力需要制御システムの上に記述したものを図 1.1 に示す。なお、当該システムの詳細は第 2 章を参照とする。

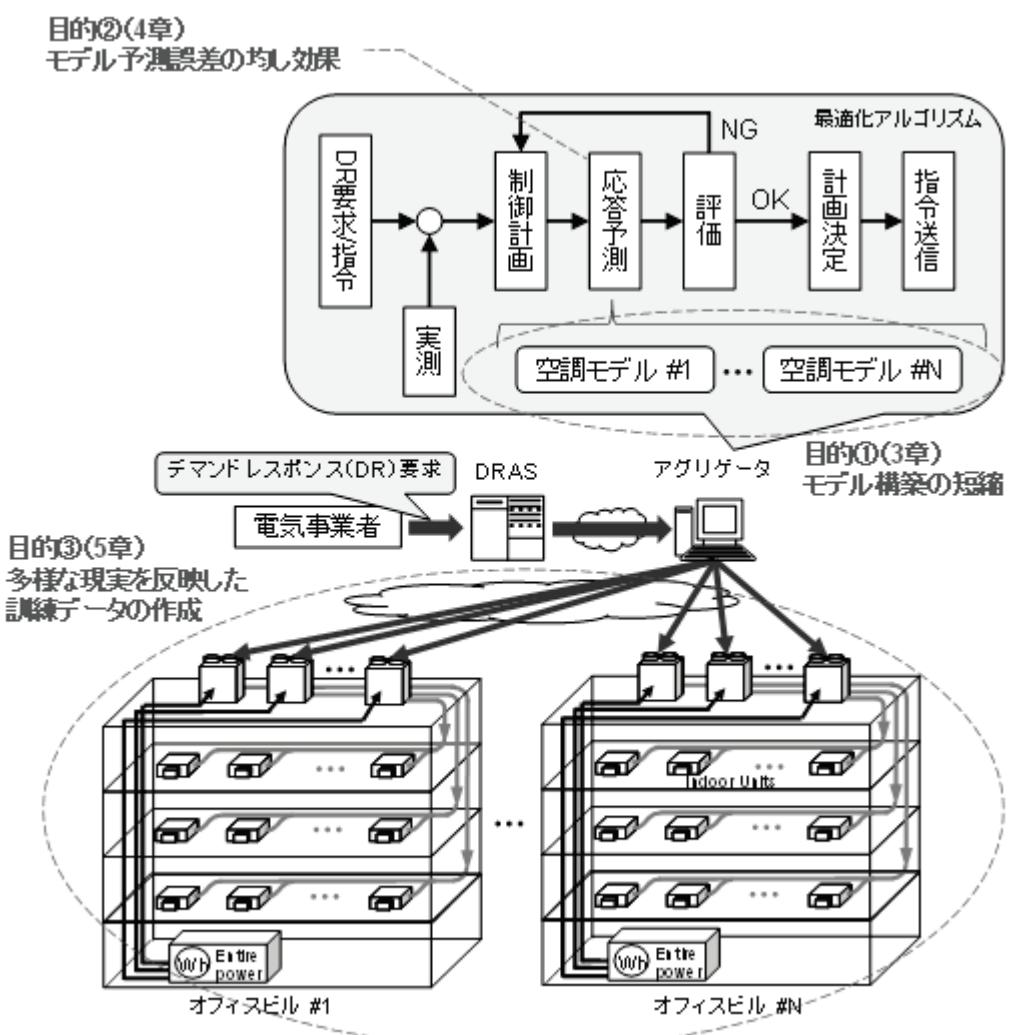


図 1.1 本研究の目的・実施事項と研究対象のシステムとの対応

第2章 設備電力需要制御システムと機械学習モデル

2.1 緒言

本章では本研究が対象とする設備電力需要制御システム及び機械学習モデルに関して述べる。まず、デマンドレスポンスとはどういったものか、スマートグリッドやリアルタイム電力料金等を含めて説明する。次に、デマンドレスポンスの対象としてのビルマルチ空調機について説明する。最後に本論文が想定する設備電力需要制御システムの構成とそこで用いる機械学習モデルを示す。

2.2 スマートグリッド

従来の電力網は、発電所から（電力を消費する）需要家への一方向に電力が流れるものであった。しかし、近年太陽光発電などの分散型電源の普及などにより、電力の流れが双方向になりつつある。そのため、現状の設備だけでは電力制御は難しい。加えて、安定供給や信頼性の向上、地球温暖化対策などといった旧来からの課題もある。

そこで、それら課題を解決することを目的に、情報通信技術と電力制御技術を融合させ、需要家サイドの制御も取り込んだ電力の効率的・合理的運用を可能にする新しい電力ネットワークが考えられている。こういった新しい電力ネットワークの概念をスマートグリッド（次世代電力網）と呼ぶ。

2.3 高速自動デマンドレスポンス (FastADR)

スマートグリッドの関連技術として、デマンドレスポンス (DR : Demand Response, 需要応答) がある。新エネルギー・産業技術総合開発機構 (NEDO) による定義[33]は「即市場価格の高騰時または系統信頼性の低下時において、電気料金価格の設定またはインセンティブの支払に応じて、需要家側が電力の使用を抑制するよう電力消費パターンを変化させること」であり、端的には（ビルや家庭などの）需要家に対して電気事業者側から働きかけることを出来るようにする仕組み全般を指す。

デマンドレスポンスは、人間が介在して需要家の電力抑制を実現するものと、人間が介在せずICTにより自動的に需要家側の負荷を制御するものの2つに分けられ、特に後者は自動デマンドレスポンス (ADR : Automated Demand Response, 自動需要応答) と呼ばれる。さらに自動デマンドレスポンスでも需要家が分単位で応答するものは高速自動デマンドレスポンス (FastADR : Fast Automated Demand Response, 高速自動需要応答) と区別される。

自動デマンドレスポンスシステムの一例を図2.1に示す。この図を用いて、電気事業者 (Utility/ISO) 側で電力需給のひっ迫が予測された場合における、自動デマンドレスポンスによる負荷制御の流れを説明する。

電力需給のひっ迫が予想されたとき電気事業者は、自動デマンドレスポンスの司令官にあたるDRAS (Demand Response Automation Server)に対し、その解消に必要となる電力を抑制するための指令を設定する。DRASは登録された需要家（大口需要家やアグリゲータ等）に設置されたクライアントに対してこの指令を送信する。指令を受信した需要家は指令に基づき負荷を適切に制御する。このような手続きが自動でおこなわれた結

果、電力需給のひつ迫は解消される。このデマンドレスポンスにおける指令にはいくつのかの種類があり、例えば削減電力量を直接指示するものや、電気料金単価を倍に設定するものなどがある。

ここでアグリゲータ（Aggregator）とは、広域・複数存在する需要家負荷設備をアグリゲーション（集約）し、一つの大口需要家に見せるものである。これにより、単独では制御が難しい設備や規模が小さい設備でも扱えるようになる。

本例のアグリゲータは複数の中小オフィスビル群の負荷設備を集約しており、DRAS から疑似的な大口需要家と扱えるように各負荷設備を制御して合計使用電力を減らす。つまり、自動デマンドレスポンスの場合、アグリゲータは DRAS からの指令を受け、何らかのアルゴリズムに基づいてビル負荷設備の制御等を自動でおこなうことで電力削減を実現する。

本研究では、将来を考え 10 分程度で需要家が応答するような FastADR を研究対象とした。

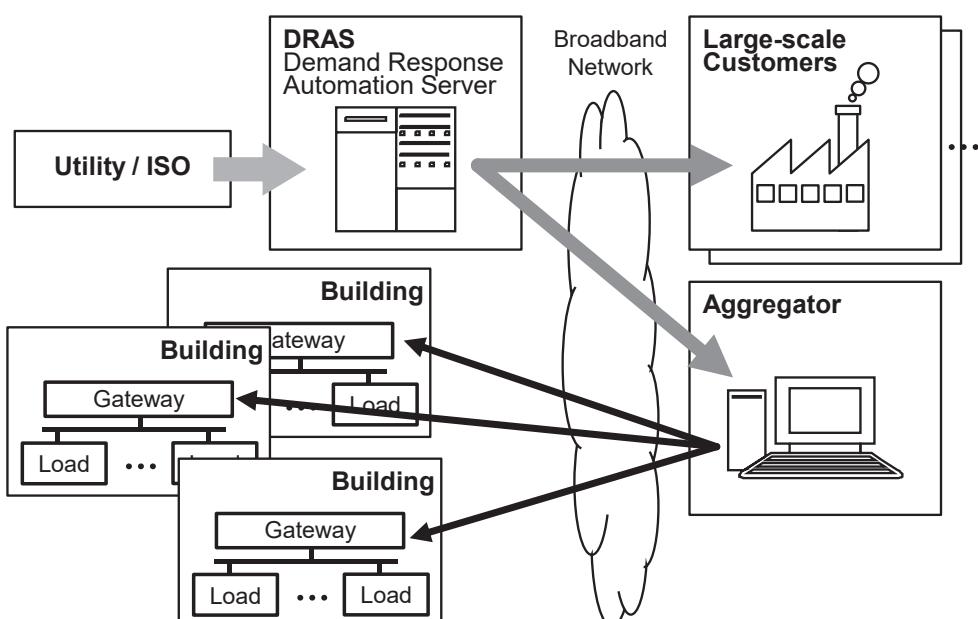


図 2.1 自動デマンドレスポンスシステムの一例

2.4 デマンドレスポンスの実現方式

デマンドレスポンスの実現方式は、ネガワット取引方式とリアルタイム電力料金(RTP: Real Time Pricing)方式の2つに大別される。

ネガワット取引方式は、送配電業者や小売業者等の電気事業者と需要家間の契約に基づき、需要家の電力削減時に報奨(インセンティブ)が支払われる方式である。通常この方式の場合、需要家側のメリットとして削減時の報酬に加えて、デマンドレスポンスに対応できる体制に対する報酬、つまり削減可能な容量に対する報酬も支払われることが挙げられる。また、電気事業者側のメリットとしては契約に基づく確定的な電力応答が期待できる。

リアルタイム電力料金(RTP)方式は、消費電力を抑制したい時間帯に電気事業者が電力料金単価を高く設定することで、間接的に需要家の電力を削減する方式である[34][35]。この方式は、電気事業者側は電力料金単価を通知するだけであるため、需要家との電力削減量の調整やデマンドレスポンスに対する報酬が不要となるメリットがある。一方、電力料金単価に対する電力応答は需要家によって異なるため、デマンドレスポンスによる電力削減結果の予測が困難となるデメリットがある。

既に米国では、送電会社によるリアルタイム電力料金の電力料金体系が実現している[89]。米国PJMで実施されたリアルタイム電力料金の変化の一例を図2.2に示す。この図の通り、電力料金単価は1時間間隔で一日を通して変動し、特に逼迫した際は、緊急ピーク時課金(Critical Peak Pricing: CPP)により通常の4~7倍の単価となる。実際には、数分間で数十倍になったという事例も米国から報告されている[36]。

ただし、将来太陽光発電や電気自動車が大量導入された場合を考えると、RTPで電力需要と供給の均衡を保つためには、単価の変動間隔(制御フレーム)をより短時間とする必要があるかもしれない。ゆえに本研究においてリアルタイム電力料金方式を扱う場合、電力料金単価の変動間隔は10分と短い場合を想定する。

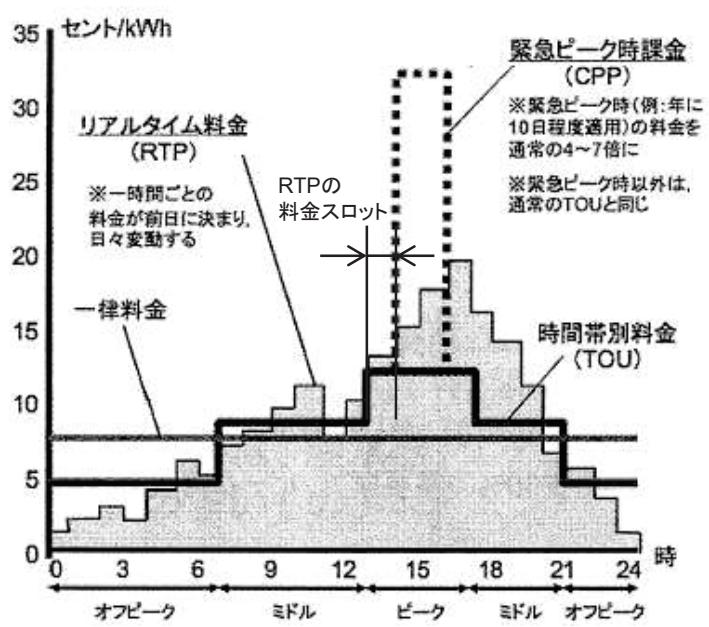


図 2.2 米国 PJM におけるリアルタイム電力料金単価の推移
引用: 電力中央研究所, 米国における家庭用デマンドレスポンス・プログラムの現状[89]

2.5 ビルマルチ空調機設備とアグリゲーション

2.5.1 ビル空調システムとデマンドレスポンス

FastADRの制御対象となる負荷設備には、蓄電池、照明等様々なものが検討・利用されているが、ビル空調システムは、ビルエネルギー管理システム（BEMS）で集中管理されていることが多い、ビル全体の合計電力の4割を占める[25]といわれていること、短時間であれば電力を抑制しても建物自体の蓄熱性により室温変動が緩やかであることから、設備負荷の抑制がしやすい対象だといえるため、本研究ではビル空調システムをデマンドレスポンスの対象として考える。

ビル空調システムはセントラル空調とビルマルチ空調の大きく2種類がある[26]-[28]。セントラル空調は中央熱源型とも呼ばれ、ビル内の中央機械室に冷凍機やヒートポンプ等を集中して設置し、そこで発生した温冷水を用いて空調をおこなうものである。

ビルマルチ空調はVRF（Variable Refrigerant Flow）[27]型空調とも呼ばれ、空調機を各部屋に分散して設置するものであり、屋外に設置された室外機のコンプレッサーをインバータ駆動させ、室内に設置した室内機に冷媒を送り空調をおこなう。

本研究では、ビルマルチ空調設備を対象としたデマンドレスポンスを研究対象とする。その理由は、後述の通りインバータ駆動負荷のこまやかな制御が可能[1]であること、指令に対する応答が10分程度と高速であること、国内だけでも推定130万台数が設置されており十分な規模であること等から、より有望な候補の一つであると考えているからである。

2.5.2 ビルマルチ空調設備

図2.3はビルマルチ空調設備の模式図である。この図で示すように、ビルマルチ空調設備は1棟のビルに対して数台の室外機と数十台の室内機からなる。そして、1台の室外機には複数台の室内機が接続されて一つの冷媒回路ブロックを構成し、室外機ユニットより冷媒を供給された室内機ユニットが熱交換をして空調をおこなう。

室外機ユニットは普通屋上に設置され、室内機ユニットは各部屋の天井に埋め込まれ形で設置されることが多い。これら空調設備が利用する電力は、電力網から室外機に對して供給される。この供給される電力は主に室外機ユニットにおいて冷媒の圧縮・各室内機への配給のために使われる。つまり、空調の電力消費の大半は室外機にある圧縮機によるもので、その比率は約90%程度といわれる。

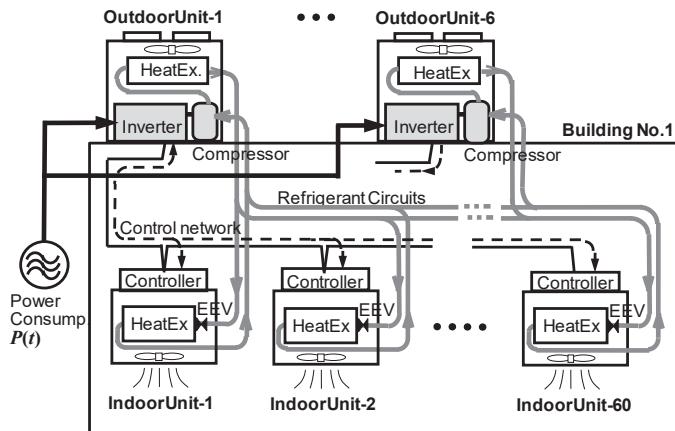


図 2.3 Complicated refrigerant circuits and control network of multi-type building air-con facilities.

室外機ユニットはインバータ駆動のコンプレッサーと熱交換機をもつ。また、各室内機ユニットは熱交換機および電気膨張弁(EEV)、コントローラーをもつ。室内機ユニットのコントローラーは EEV を制御し、室内機の熱負荷に従い熱交換機に流れる冷媒の流量を調整する。すべての室内機と室外機ユニットは通信ネットワーク線に接続される。

2.5.3 ビルマルチ空調機設備とアグリゲーション

従来のビルマルチ空調設備に対するデマンドレスポンスは、1時間といった粗い時間粒度で、電力制限量も下げすぎても構わないといった緩やかな制御条件であった。そのため、運転台数変更、設定温度変更といった間接的な操作指令により時間単位の消費電力量を削減するものであった。しかし、FastADR が目指すのは分単位の時間粒度でかつアグリゲータが目標とする値に合うよう精密制御することを想定している。故にビルマルチ空調機によるデマンドレスポンスにおいて、空調電力を直接的に数値で精密抑制制御するには、運転台数とか設定温度でなくて直接的に空調機組込みの制御装置に電力数值目標を指令することが望ましい。

先述の通り、ビルマルチ空調機の消費電力の約 90%を占める圧縮機はインバータ駆動されているので連続的に細かく消費電力を制御可能であり、精密な FastADR 電力制限が期待できる。そこで本研究では、FastADR 電力制限の手段として、遠隔ビルマルチ空調設備に対して圧縮機インバータ電力の抑制目標値（電力制限指令値 P_L^b ）を明示的に指令する方式を仮定する。

この抑制目標値とは、いわゆる制御理論における目標値とは異なり、消費電力の上限を設定したものである。また、抑制目標よりも冷媒回路を維持するための組込み制御が優先されるため、目標値に一致するよう電力が消費されるとは限らない。その組込み制御の要因は、(i)空調負荷が低くて抑制値より現在の温調電力が小さい、(ii)圧縮機の最低回転数に相当する電力には抑制できない、(iii)設備保護運転（圧縮機潤滑油回収）の数分間は大電力を消費する、などがある。したがって図2.4に示すように、個々のビルマルチ空調機の分刻み電力応答波形はFastADR電力制限指令値に対して過渡的に上回る時間帯もあるし指令値まで消費しない時間帯もあり、一般に確率的な応答波形にみえる。

ビルマルチ空調機によるFastADRにおいて、この複雑な冷媒回路の分散型組込み制御に起因する不確実性は問題となりうる。加えて、系統から要求される電力需要抑制単位は最低1MWオーダーであるのに対し、個々のビルマルチ空調機の抑制可能な消費電力幅がkWオーダーであるため非常に小さいという問題がある。

このうち不確実性の問題の解決策の一つに大量の台数のアグリゲーション（集約）が考えられる。これは同じく個々の装置では不確実性をもつ太陽光発電や風力発電で試みられた均し効果による解決策である。この方策により大量な台数でアグリゲーションをおこなうことで消費電力規模を大きくみせることが出来るために消費電力規模の問題も解決するだろうと考えられる。そこで本研究では、ビルマルチ空調機をアグリゲータによりアグリゲーションをおこなったシステムを対象とした。

例として、個々のビルマルチ空調機の電力制限指令応答波形を複数重ね合せていく、疑似的にアグリゲーションしたものを図2.5に示す。この図は個々の実測応答波形と電力制限指令値と重ね合せ波形を並べて表示している。個々の応答波形実験・予測値は、図の最上段に示すように確率的な組込み制御や外乱のために電力制限指令値と大きくはずれる場合がある。しかし、重ね合せ数Nを増やしていくにつれて応答波形は均し効果により期待値に収束していくと考えられる。

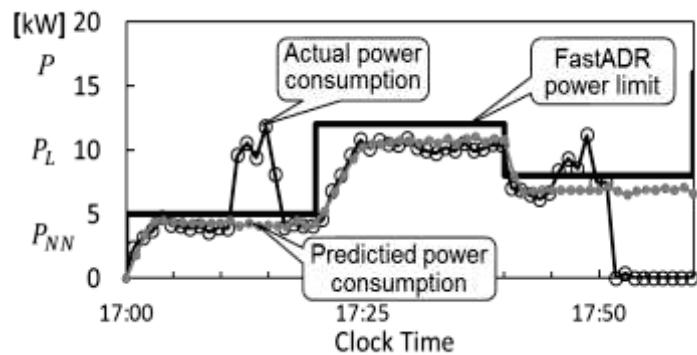


図 2.4 Stochastic behavior of FastADR responses of a multi-type building air-conditioner

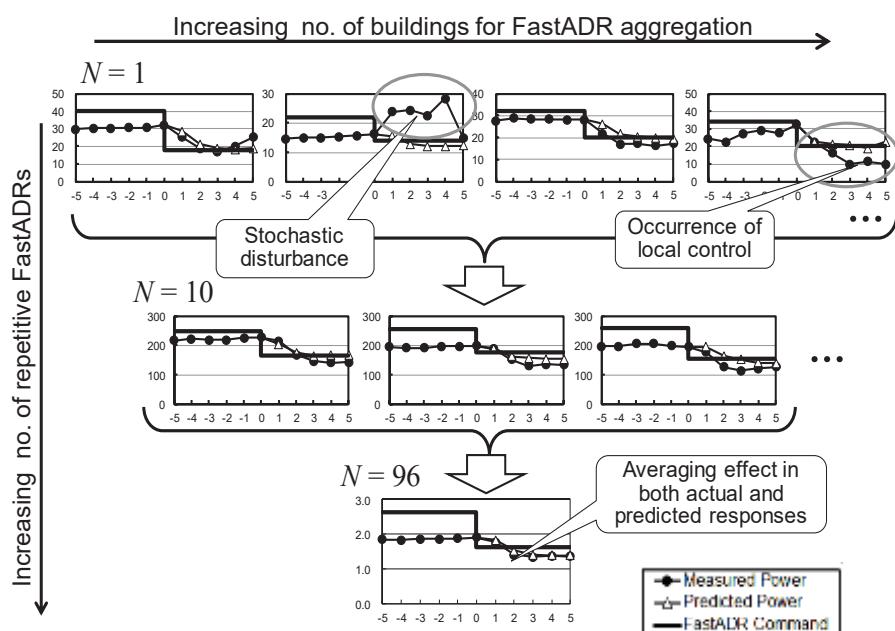


図 2.5 Averaging effect on FastADR aggregation of a large number of building-multi air-conditioning facilities

2.6 設備電力需要制御システム

本研究が想定するデマンドレスポンスにおけるビルマルチ空調機設備を対象とした電力制御システム（以降、設備電力需要制御システム）の構成図を図 2.6 に示す。本論文では当該システムがクラウド上にあり、インターネット通信を経由して遠隔でビルマルチ空調機の消費電力を制御する方式を考える。

設備電力需要制御システムでは、電気事業者 (Utility/ISO) 側のデマンドレスポンス要求により DRAS からアグリゲータに合計電力制限指令 P_{LA} [kW] が通知される。アグリゲータは、各ビルのビルマルチ空調機設備の消費電力と室温等の時系列を基にして、 P_{LA} を満たすように各室外機の電力制限指令値 P_L^b [kW] (P_L^1, P_L^2, \dots) を決定する。ここで、 P_L は電力制限指令値を表し、各室外機の圧縮機消費電力 P^b [kW] (P^1, P^2, \dots) の上限を制限するものである。上付き記号 b はビルマルチ空調機の室外機系統 Block 番号 ($b = 1, 2, \dots$) を表す。各ビルのビルマルチ空調機設備はアグリゲータから受信した電力制限指令値に従い、各室外機の消費電力 P^b を抑制する。

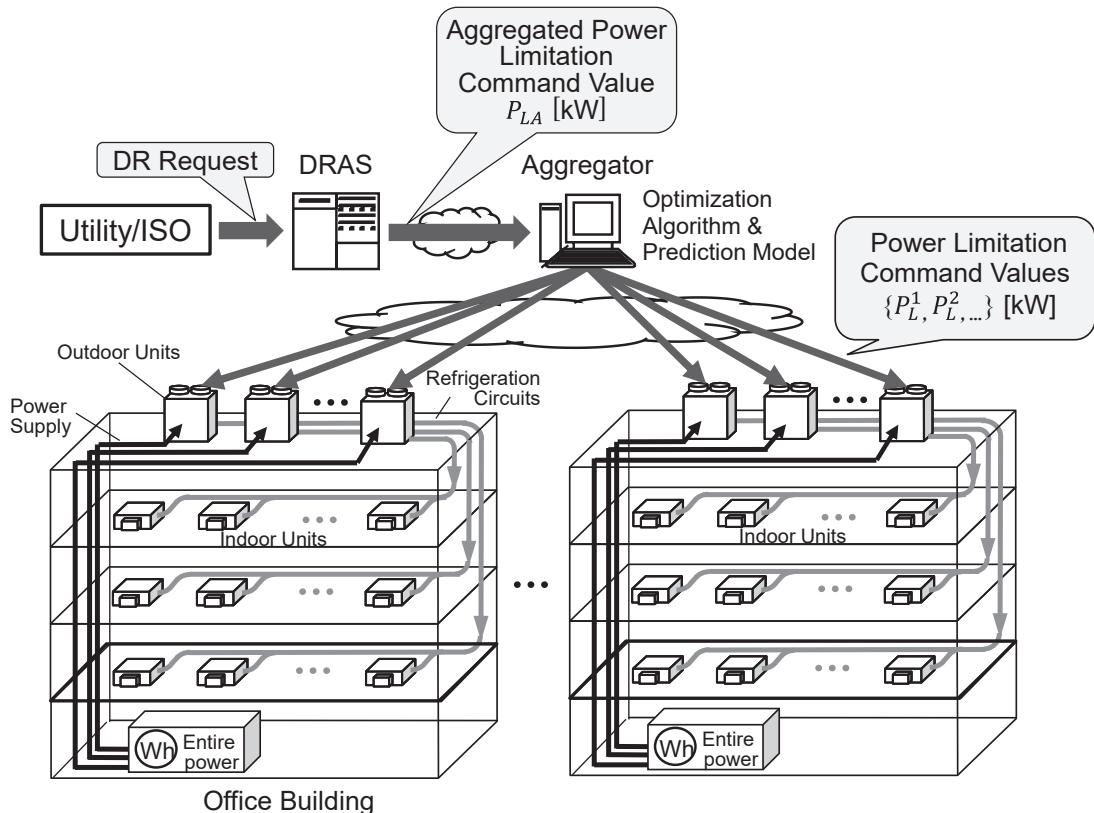


図 2.6 ビルマルチ空調機設備電力需要制御システム

また、本研究ではビル1棟を設備電力需要制御システムの取扱い単位とするので、それに対応するビル1棟全体の室温パラメータとして、各室内機の室温と設定の偏差に室内機定格冷房能力 C_i の重みをつけて平均した平均室温偏差 T_{SA}^b [deg]を定義する。

$$T_{SA}^b(t) = \left\{ \sum_{i=1}^{N_{IU}} C_i \cdot (T_{Ai}^b(t) - T_{Si}^b(t)) \right\} / \sum_{i=1}^{N_{IU}} C_i^b \quad (2.1)$$

ここで t は分刻み離散時刻[min], i は室内機番号 ($i = 1, 2, \dots$), $T_{Ai}^b(t)$ は各室内機室温センサー値, $T_{Si}^b(t)$ は各室内機設定温度, C_i^b は各室内機定格冷房能力である。

2.6.1 RTP 設備電力適応制御システム

先述の設備電力需要制御システムはネガワット取引方式によるものである。一方、リアルタイム電力料金 (RTP) 方式によるビルマルチ空調機設備電力需要制御システム（以後、RTP 設備電力適応制御システム）は図 2.7 となる。想定する RTP 制度は 10 分単位で単価が変動するものであるから、本システムでは DRAS がアグリゲータに通知するものが数十分先までの電力料金単価 R [¥/kWh] のスケジュールに置き変わる。

先の設備電力需要制御システムと同様に、アグリゲータは各室外機の電力制限指令を

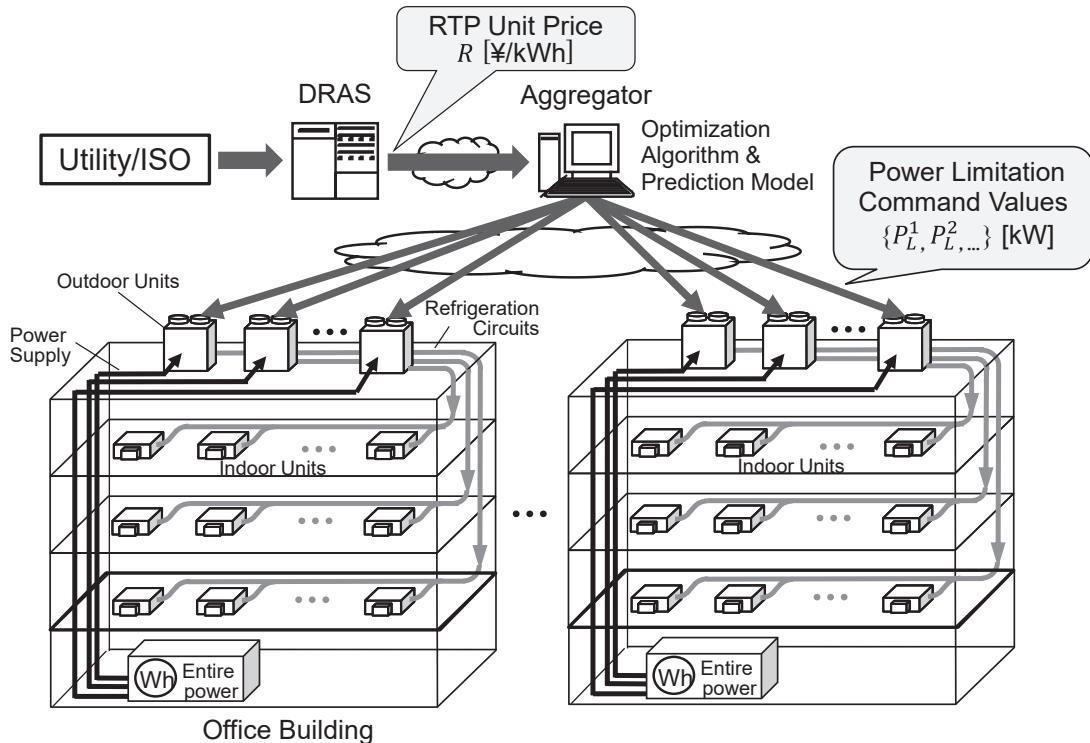


図 2.7 リアルタイム電力料金適応制御システム

決定・送信するがその制御目標は異なる。電力事業者との契約が発生する設備電力需要制御システムでは、アグリゲータは合計電力が合計電力制限指令を満たすような制御が必要となる。対して、そういった契約のない RTP 設備電力適応制御システムは、ビル全体の電力料金と室温快適性のトレードオフを考慮したうえで料金単価スケジュールに基づき料金を最小化するような、つまり RTP に適応した制御が必要となるだろう。

本研究の RTP 設備電力適応制御システムでは、将来の電力料金単価とビルマルチ空調機の電力と室温応答を基に、先の電力制限指令値 P_L^b スケジュールを計画する。なお、本研究では料金単価変動周期を 10 分、制御周期（フレーム）を 5 分とし、通知済み電力料金単価の変更はないものとする。

電力制限指令値 P_L^b スケジュールは、電力料金と室温快適性に関する評価関数 J_i^b を定め、目的関数 J_i^b を最小化するような決定変数（電力制限指令値スケジュール）の適応解を、ビルマルチ空調機設備の電力室温予測モデルを用いて Simulated Annealing (SA) アルゴリズム[45]により探索することで計画される。つまり、電力室温予測モデルの予測結果次第で、電力制限指令値スケジュールの探索結果も変わる。

電力料金と室温快適性に関する評価関数 J_i^b は、室温快適性を設定温度と室温の差が少ないほど良いとして次式で定義した。

$$J_i^b = \alpha \sum_{m=1}^{m_{max}} R(m) \cdot W_5^b(m) + (1 - \alpha) \sum_{m=1}^{m_{max}} Z^b(m) \quad (2.2)$$

ここで、 m はフレーム番号、 $R(m)$ は 5 分制御フレーム毎単価[¥]、 $W_5^b(m)$ は 5 分間ビルマルチ空調機電力量[kWh]、 α (0.0~1.0) は料金・室温バランス係数、 $Z^b(m)$ は室温ペナルティである。 $Z^b(m)$ は 5 分制御フレーム中 4 分目の平均室温偏差 $T_{SA}^b(m)$ を用いて、次式で定義した。

$$Z^b(m) = [T_{SA}^b(m)]^2 \quad (2.3)$$

また、決定変数である電力制限指令値 P_L^b の制約条件は以下のとおりである。

$$P_L^b = P_{max}^b \cdot n_L / (N_L - 1) \quad (2.4)$$

ここで、 P_{max}^b は定格消費電力[kW]、 N_L は電力制限指令値の離散化段数、 n_L は指令ステップ ($n_L = 0, 1, \dots, N_L - 1$) であり、 P_{Lm}^b は $0 \leq P_{Lm}^b \leq P_{max}^b$ の範囲をとる。本論文では、各指令ステップの消費電力と室温の応答に有意な差が生じる離散化段数として $N_L = 5$ を用いる。

2.7 ビルマルチ空調機設備の機械学習予測モデル

デマンドレスポンスのネガワット取引方式において、アグリゲータは削減可能な容量に対して報酬を得ることが可能である。言い換えれば、ビルマルチ空調機設備の削減可能な電力量の予測が出来なければ契約が出来ない。一方、リアルタイム電力料金（RTP）方式ではそのような必要条件はないが、室温快適性を維持しつつ料金を最小化するような電力制限指令の探索には、前節で説明するようにビルマルチ空調機設備の電力や室温の予測が出来なければならない。ゆえに、ビルマルチ空調機設備の予測モデルが必要である。

ビルマルチ空調機設備は、先に述べた組み込み制御に起因する不確実性に加え、ユーザ操作や利用状況による突発的な変化等があるため、その応答時系列を観察すると、確率的なふるまいや、非線形的に見える応答がある。また、ビルマルチ空調機設備の応答はメーカや型番、稼働設定による違いだけではなく、設置ビルの構造や設置箇所、稼働状況等の外部環境要因でも異なると考えられる。

そのため、特に今回目的とするような数分～數十分程度の短時間の応答を扱う場合、単純なモデル（例えば一次遅れモデル）では不確実性の予測が十分ではなく、さまざま要因により発生しうる空調機応答の多様性を示すことにも適していない。

そこで本研究では、機械学習分野のニューラルネット（Neural Network: NN）による単純な構造のモデルをビルマルチ空調機設備の予測に用いることにした。NNを選択した理由は、非線形的な分野において良い結果を得られていると知られていること、訓練データ数が十分に揃うことが出来れば一定の精度が期待できることである。また、機械学習分野は近年発展が著しく、機械学習モデルが今後さらなる良い成果を出すのではないかと期待できるため、その利用を前提に検討することは将来においても活用できるのでは判断した。

単純な構造とした理由は、図2.8に示すようにビルやアグリゲーションの規模によつては室外機系統 Block が数十台におよぶケースがあり、各室外機系統 Block 数だけモデルを訓練構築するという膨大な開発作業が必要となるため、学習やチューニングに時間がかかる複雑なモデルは避けるべきだと考えたためである。加えて、本研究はビルマルチ空調機設備予測モデルの予測精度の向上ではないため、その点でも複雑なモデルを選択する理由は無かった。

また、ビルマルチ空調機設備の予測モデルは室外機毎に作成することにした。均し効果を期待して複数の室外機やビルの単位でモデルを作成することも可能であるが、そ

いった規模の大きいデータを用意することは現実的には困難であることから、室外機単位に決定した。

2.7.1 ニューラルネットワーク (NN) モデル

本研究でビルマルチ空調機設備の機械学習予測モデルとして使用するニューラルネットワーク (NN) モデルの構造は、時刻 t のとき電力制限指令が変化したとして、入力変数ベクトル \mathbf{x} を式(2.5)、出力変数ベクトル \mathbf{y} を式(2.6)とする MLP (Multi-Layer Perceptron) 型ニューラルネットワークである。

$$\begin{aligned} \mathbf{x} = [& P_L^b(t+1), P_L^b(t), \\ & P^b(t-4), P^b(t-3), P^b(t-2), P^b(t-1), P^b(t), \\ & T_{SA}^b(t-4), T_{SA}^b(t-3), T_{SA}^b(t-2), T_{SA}^b(t-1), T_{SA}^b(t), \\ & T_o^b(t)]^T \end{aligned} \quad (2.5)$$

$$\begin{aligned} \mathbf{y} = [& \widetilde{P^b}(t+1), \widetilde{P^b}(t+2), \widetilde{P^b}(t+3), \widetilde{P^b}(t+4), \widetilde{P^b}(t+5), \\ & \widetilde{T_{SA}^b}(t+1), \widetilde{T_{SA}^b}(t+2), \widetilde{T_{SA}^b}(t+3), \widetilde{T_{SA}^b}(t+4), \widetilde{T_{SA}^b}(t+5)]^T \end{aligned} \quad (2.6)$$

ここで、 $T_o^b(t)$ は外気温[°C]であり、 $\widetilde{\cdot}$ はニューラルネットワークで出力した予測値であることを示す。また、活性化関数はシグモイド関数を利用する。

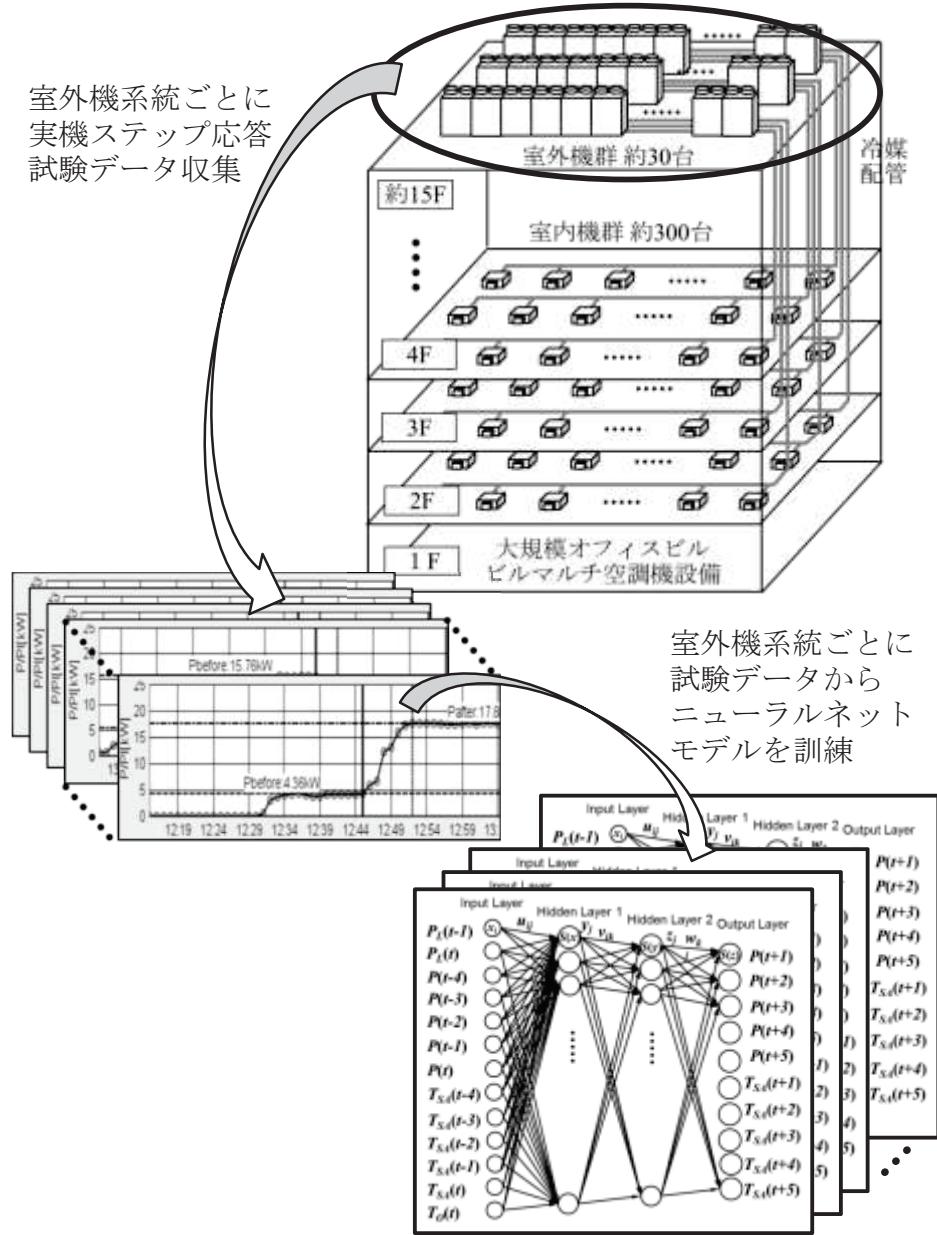


図 2.8 大規模ビルにおける大量ニューラルネットワークモデル群の訓練構築

2.8 設備電力需要制御システムの制御

本研究における設備電力需要制御システムの制御には、いわゆる制御工学における制御とは異なる点がある。それは、ビルマルチ空調機設備における電力目標に対する制御が設備の機能として通常組み込まれており、設備保護機能等の他機能と併せて自立的に運転し、その制御工学上の制御応答性（目標値への到達速度）はデマンドレスポンス要求の制御フレーム（数分～数十分）に対し十分である点である。

先に述べた通り、設備電力需要制御システムの制御はビルマルチ空調設備の組み込み制御運転に対して目標上限値（電力制限指令）を設定する形である。ゆえに設備電力需要制御システムの制御応答性は個々の空調設備の制御応答性により決まるものではなく、ユーザ操作や設備保護運転、デマンドレスポンスからの離脱（Opt-Out）等に伴う突発的な応答や、温調制御に必要な電力（温調所要電力）が小さい場合や設備自体が停止している場合の目標上限以下の応答により発生するオフセットへの追従により決まるものだと考える。

しかし、本研究ではそのオフセットを打ち消すようなシステム全体のフィードバック制御は実施しない。これはアグリゲータがインターネット越しに大量のビルマルチ空調設備をフィードバック制御することは、設備電力の計測・伝達遅延やネットワーク遅延の存在や、現実的な通信頻度（1分程度）を考えると難しいことが主な理由である。代わりにアグリゲータは蓄電池等によりオフセットを打ち消すと想定するが、それは本研究の管轄外である。

したがって、本研究における設備電力需要制御システムの制御応答性は、オフセットの幅で主に評価するものである。

2.9 設備電力需要制御システムと応答時間

設備電力需要制御システムの電力制限指令に対する応答時間を検討する。このシステムの応答時間には、制御対象のビルマルチ空調設備自身の応答時間の他に、FastADR 発令直前のネゴシエート手続き時間や、通信制御処理時間も考慮が必要であるだろう。しかし、ネゴシエート手続き時間や通信制御処理時間に関しては人為的・制度的な側面が強く、これら時間やそのバラツキを考慮することは現時点では困難だと思われる。本研究では別途言及がない限り、ネゴシエート手続き時間や通信制御処理時間については対象外とし、制御対象設備の応答時間、つまり電力制限指令が伝わってからの応答のみを評価する。

2.10 結言

本章では本研究の対象であるデマンドレスポンス、デマンドレスポンスの対象としてのビルマルチ空調機、設備電力需要制御システムの構成、機械学習モデルを説明した。

第3章 設備電力需要制御モデルの機械学習

3.1 緒言

ビルマルチ空調機の予測モデルを用いた応用サービスの一つに、短い時間で単価を変更するリアルタイム電力料金制度（Real-Time Pricing : RTP）があり、これまで我々はビルマルチ空調機群を対象に料金節約と空調快適性とを両立させる RTP 適応制御方式を開発してきた[37]。この方式では電力制限指令値の候補から最適値を探査するので、電力制限指令に対する電力・室温の応答を予測するモデルが不可欠である。

ビルマルチ空調機の電力・室温の応答を予測するモデルをニューラルネットワークでモデリングする場合、通常は訓練データ収集のため電力制限指令に対する実機ステップ応答試験などの専用試験が必要である。しかし、専用試験はビル居住者への負担と試験時間の問題が大きいため、それに代わるデータ収集方式が実用化の鍵である。従来研究[38]では、居住者の負担低減のため小信号の電力制限指令を印加する Modulation 方式も提案されたが、開発時間面では依然として問題があった。

本章では、訓練データ取得のための専用試験なしで、元々存在する平常運転時系列から訓練データを抽出する新方式を試行する。この新抽出方式は、DNA 遺伝子解析アルゴリズムを訓練データ抽出に応用するという我々のアイデア[39]を具体化させたものである。それは DNA 遺伝子コピー数確率分布が急変する位置を特定する数理技術を、空調機の平常運転時系列から電力消費が急変する時点の抽出に応用するというアプローチである。さらに、平常運転時系列には電力制限指令がないので、上記の電力消費急変点の前後に仮想電力制限指令を付加する訓練データ合成法を組合せたことが特徴である。

本方式により訓練データを抽出した場合と従来方式の場合について、シミュレーション実験により応用サービス（RTP 適応制御）上の性能比較及び訓練データ収集時間を比較した。

3.2 平常運転からの機械学習訓練データ抽出

3.2.1 専用試験によるデータ収集

我々の先行論文[37]では、ニューラルネットワークの訓練に実機ビルマルチ空調設備の専用試験データを用いている。これは Modulation 方式を用いて収集したものである。Modulation 方式は空調調節設備運転中に小信号の電力制限指令 P_L^b を重畠する方式である。小信号の Modulation をおこなうことで、居住者が感知できないようにし最適性を維持する。このとき、ビル使用者の快適性が失われてしまうことを防ぐため、居住者が不快となる室温の閾値を設定し、それを超える間は電力制限指令を開放するようしている。

小信号の電力制限指令 $P_L^b(m+1)$ は、制御フレーム（5分）毎に現在の使用電力値 $P_{NEW}^b(m)$ を中心とした5段のステップから乱数で選択する。

$$P_L^b(m+1) = P_{NEW}^b(m) + P_{WD} \cdot R_D \quad (3.1)$$

$$R_D = \frac{rnd}{\text{floor}\left(\frac{R_{STEP}}{2}\right)} \quad (3.2)$$

ここで、制御フレーム番号は m 、 $P_{NEW}^b(m)$ は $m+1$ 番目のフレーム開始 3 分前の電力値 [kW]、 P_{WD} をランダム変更半幅、 R_{STEP} を離散化ステップ数 (=5) と定義する。ただし、 $P_L^b(m+1)$ の出力範囲は定格消費電力の範囲内にした。

3.2.2 平常運転データと電力制限指令

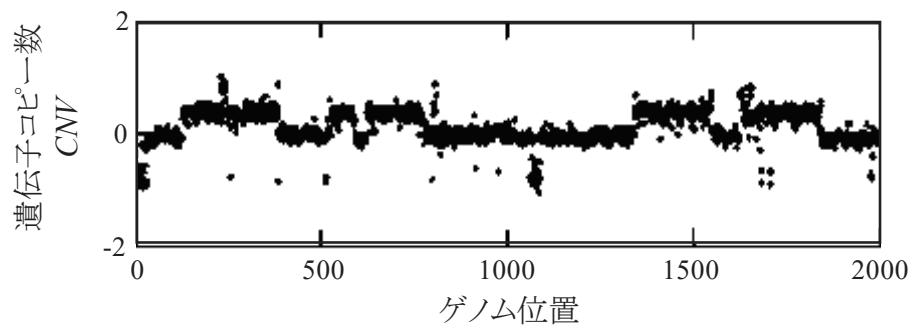
本章では、Modulation 方式のような電力制限指令値 P_L^b を設定する専用試験をせずに平常運転データだけを用いることを試みる。このとき、 P_L^b がデータに含まれないことはもちろん、それをステップ状に変化させた際のビルマルチ空調の応答が直接的には存在しないことが問題となる。しかし、専用試験で P_L^b をステップ状に印加した場合におけるその前後の電力 P^b の急変点について、同じ変化率の応答が平常運転時系列においても発生すると仮定すると、平常運転データから急変点前後を抽出することで同等のステップ状応答を得る可能性があり、この応答を発生しうる P_L^b のステップ変化を仮想制限指令変化と見なせる。なお、急変点とはその前後のデータ点の分布が大きく変化する点を指す。

以上をまとめると、平常運転データから応答訓練データを得るには、電力 P^b の急変点を基準に抽出すること、対応する仮想電力制限指令 \widehat{P}_L^b を求めること、この 2 点が解決すべき課題である。

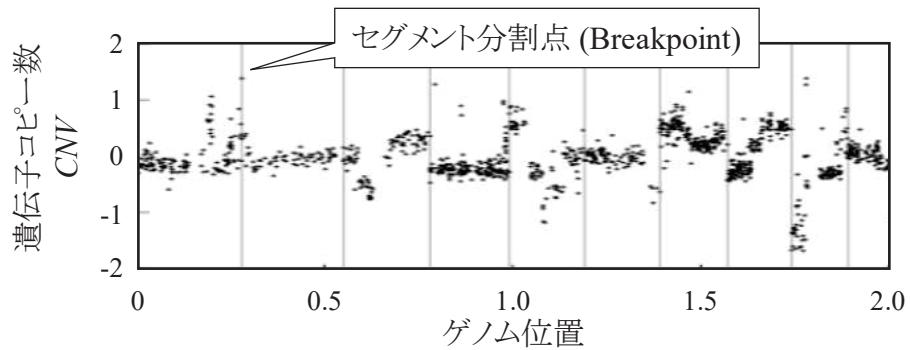
3.2.3 Breakpoint 訓練データ収集方式

これら課題のうち、第一の問題の改善を目指した急変点の抽出方式として、我々は新しいアイデアである Breakpoint 方式[39]を案出した。このアイデアでは Breakpoint アルゴリズム[40][41]という DNA 遺伝子解析を目的に開発された Cross-Entropy 法[42]に基づくアルゴリズムを利用する。本章では、この Breakpoint 方式と 3.2.4 項で提案する「仮想電力制限指令」方式を併用して複合制御への有効性を検証する。

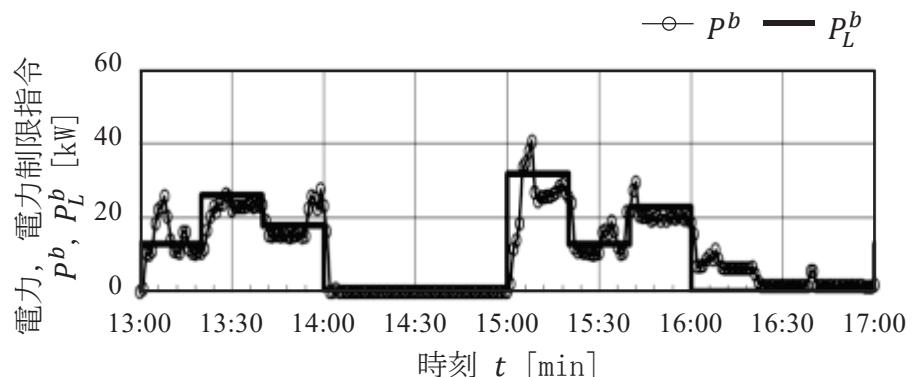
図 3.1(a)(b)に、Breakpoint アルゴリズムが対象とする遺伝子データの例[43]を示す。横軸はゲノム位置番号、縦軸は CNV (Copy Number Variation) と呼ばれる遺伝子コピー数の通常値からの差である。通常値は、父母から受け継ぐ 2 コピーの場合で、 $CNV=0$ である。図 3.1(b)は(a)の横軸を拡大したもので、本 Breakpoint 方式で CNV の急変点を検出してゲノム位置セグメントに分割した一例である。



(a) DNA 情報分布の急変点



(b) Breakpoint セグメント分割点



(c) ビルマルチ電力時系列のステップ変化

図 3.1 DNA 情報のゲノム位置軸上の変化特性と
ビルマルチ空調電力の時間軸上の変化特性の例

Breakpoint 方式の分割アルゴリズムを図 3.2 と付録 A で示す。このアルゴリズムは複雑な変化点でもセグメント分割できる。そこで、横軸ゲノム位置を時刻、縦軸 CNV を電力と置き換えて、電力時系列実測データから複雑な急変点も検出してステップ応答訓練データを抽出することを狙った。

図 3.1(c)はビルマルチ空調の電力 P^b 時系列を比較した例を示す。この図に示すステップ状急変に似た傾向を図 3.1(a)の遺伝子データが示すことから、本アルゴリズムにおいて遺伝子データを示す要素数 L の観測データベクトル $\mathbf{v} = (v_1, v_2, \dots, v_L)$ を P^b の時系列データ $\mathbf{P}^b = (P^b(1), P^b(2), \dots, P^b(L))$ と見なして分割点位置を検出し、その該当する箇所の前後を時系列データセグメントとして抽出するアイデアが Breakpoint 方式である。

Definitions and Assumptions:

- Observations $\mathbf{v} = (v_1, v_2, \dots, v_i, \dots, v_L)$ of Length L
- Segmentation v_i is independently distributed as normal with mean μ and common variance σ^2
- Number of breakpoints N
- Breakpoint location vector $\mathbf{C} = (c_1, c_2, \dots, c_j, \dots, c_N)$, where $1 < c_1 < \dots < c_N < L + 1$
- Breakpoint locations c_j 's are simulated by four parameter beta distribution $f(v; \alpha, \beta, 1, L)$

Algorithm:

- (1) Choose initial value for $\boldsymbol{\alpha}^0 = (1, 1, \dots, 1)$ and $\boldsymbol{\beta}^0 = (1, 1, \dots, 1)$ and set $t = 1$.
- (2) Generate random candidates $\mathbf{C}^{(1)}, \mathbf{C}^{(2)}, \dots, \mathbf{C}^{(m)}, \dots, \mathbf{C}^{(M)}$ using Beta($\boldsymbol{\alpha}^{t-1}, \boldsymbol{\beta}^{t-1}$).
- (3) For each $m = 1, 2, \dots, M$, sort locations $c_j^{(m)}$ in $\mathbf{C}^{(m)}$ from smallest to largest.
- (4) Evaluate mBICs performance score F of each location vector $\mathbf{C}^{(m)}$.
- (5) Select the elite sample M_{elite} , which is candidates of the breakpoint locations.
- (6) For all $j = 1, 2, \dots, N$, estimate Beta parameters $\boldsymbol{\alpha}^t = (\alpha_1^t, \alpha_2^t, \dots, \alpha_N^t)$, $\boldsymbol{\beta}^t = (\beta_1^t, \beta_2^t, \dots, \beta_N^t)$ using M_{elite} and update current parameter set.
- (7) Evaluate the stop condition. The stop condition is that stop the process if $\max_j \text{MAD}_j < \varepsilon$, where, $\text{MAD}_j = \text{Median}(c_j^{(1)}, c_j^{(2)}, \dots, c_j^{(M)})$ | for all $j = 1, 2, \dots, N$.
- (8) If the stop condition met stop to identify the best $\mathbf{C}^{(m)}$. Otherwise, set $t \leftarrow t + 1$ and go to step (2).

図 3.2 平常運転時系列からのニューラルネットワーク訓練
データ抽出方式「Breakpoint 方式」のアルゴリズム

例として図 3.3 に、Cutout アルゴリズム（単に空調電力時系列データにおいてスライド窓で複数単純条件により単純ステップ状の大信号変化を検出する）の従来方式[44]と Breakpoint 方式の 2 方式で、平常運転時系列から急変点を抽出した例を示す。

この例では、時刻 18:58, 19:56 頃の 2 か所の単純な急変点は両方式ともに抽出している。しかし、時刻 19:28 の例は、单一ステップ変化でなく途中で応答変化率が変わる電力急変点（破線で囲った部分）であり、確率分布変化点を検出する Breakpoint 方式だけが抽出できている。このように Breakpoint 方式では従来方式では検出できない変化時系列をもつ急変点も抽出できることが分かった。

一方、従来方式に対して Breakpoint 方式は図 3.2 のアルゴリズムを解くため計算量は多くなる。そのため、現実的な時間で抽出するには分割点位置ベクトルの個数 N は制限される。また、従来方式のみで急変点を検出する場合もある。そこで本章における Breakpoint 方式では従来方式による抽出も実施することで、データ数を確保している。このとき、急変点が 5 分以内にある場合は重複として扱っている。以後、この併用方式を単に Breakpoint 方式と記す。この方式で作成したモデルの精度は、文献[39]では従来方式に対して 10% 程の改善がなされたとの報告がある。

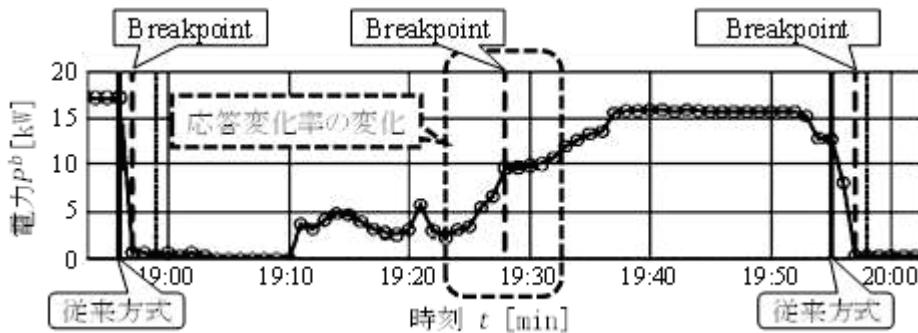


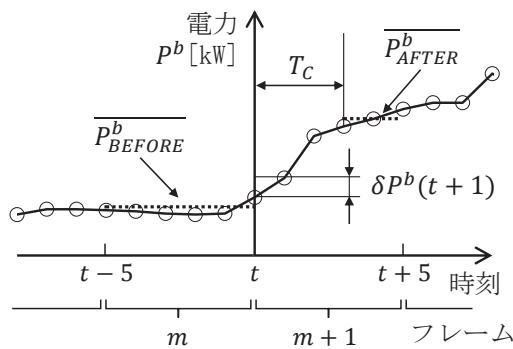
図 3.3 Breakpoint 方式による電力ステップ状変化の抽出例

3.2.4 仮想電力制限指令の提案

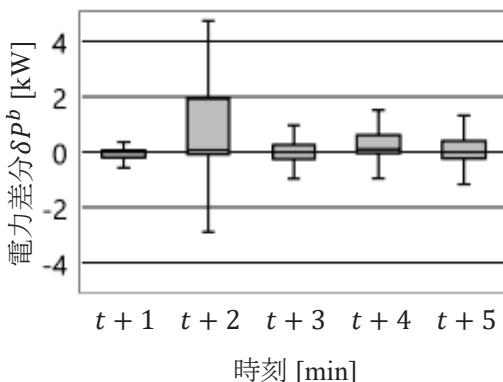
次に、もう一つの課題である仮想的な電力制限指令 \widehat{P}_L^b を決定する方法を検討する。ここで、抽出した時系列データセグメントに含まれる電力 P^b の急変点の時刻を t とし、その前後の 5 分間制御フレーム番号を $m, m+1$ とする。

このとき、仮に P^b の急変が電力制限指令の $\widehat{P}_L^b(m)$ から $\widehat{P}_L^b(m+1)$ へのステップ状の変化により発生したものとして、 P^b は応答したと考えられる。しかし、ビルマルチ空調設備の電力 P^b 変化は、電力制限指令が $\widehat{P}_L^b(m)$ から $\widehat{P}_L^b(m+1)$ とステップ変化しても、それの応答には空調制御系の遅延が存在する。

そこで本章では、次の式(3.3), (3.4)及び図 3.4(a)で示すように仮想電力制限指令 $\widehat{P}_L^b(m)$, $\widehat{P}_L^b(m+1)$ を電力時系列平均 $\overline{P}_{BEFORE}^b(m)$, $\overline{P}_{AFTER}^b(m+1)$ とし、 \overline{P}_{AFTER}^b は応答遅延時間 T_C [min] を除いた平均と定義した。



(a) 電力急変点における仮想電力制限値の合成



(b) 電力急変点前後の電力変化ばらつき分布

図 3.4 Breakpoint 方式で抽出した電力急変点の電力制限指令への対応とステップ後電力変化バラツキ分布

$$\widehat{P_L^b}(m) \triangleq \overline{P_{BEFORE}^b}(m) = \frac{1}{5} \sum_{\tau=0}^4 P^b(t-\tau) \quad (3.3)$$

$$\widehat{P_L^b}(m+1) \triangleq \overline{P_{AFTER}^b}(m+1) = \frac{1}{5-T_C} \sum_{\tau=T_C+1}^5 P^b(t+\tau) \quad (3.4)$$

専用試験で電力制限指令 P_L^b により P^b が応答する場合において、この応答遅延時間 T_C を構成するのは、制限指令取得 Pull 通信タイミング遅延やインターネット伝送遅延、空調制御遅延、空調インバータ加減速遅延等である。したがって、応答遅延時間 T_C は次に述べるよう当該空調設備の実測データに基づき決定した。

3.3 機械学習訓練データ収集とニューラルネットワークモデルの構築

訓練データ収集対象としたオフィスビルの概要を表 3.1 に示す。今回対象とした室外機系統 Block は 1 階オフィスフロアの半分（約 300m²）であり、定格冷房能力は 45kW、定格消費電力は 13.3kW である。

本章の平常運転データ計測は 2015 年 7 月～9 月の平日オフィス時間とし、Breakpoint 方式を使用して合計 257 件の電力急変データを得た。このうち、Breakpoint アルゴリズムで検出したものは 1 割程度である。比較対象となる専用試験データ計測は Modulation 方式により 2016 年 8 月にステップ応答データを 1523 件取得した。

続いて応答遅延時間 T_C を検討するために、式(3.5)で示す電力 P^b の差分 $\delta P^b(t + \tau)$ を定義する。

$$\delta P^b(t + \tau) = P^b(t + \tau) - P^b(t + \tau - 1) \quad (3.5)$$

この $\delta P^b(t + \tau)$ は電力 P^b における前時刻との差分であり、0 に近いほど変動はなく横ばいであることをいう。図 3.4(a)には例として $\delta P^b(t + 1)$ の場合の範囲を示している。

時刻 $t + 1$ 以降における $\delta P^b(t + \tau)$ のボックスウィスカープロットが図 3.4(b)である。この図より、今回の対象空調設備では、時刻 $t + 1$ では応答前の値から変わらず、 $t + 2$ で大きく急変しているものが多いと分かる。そこで電力応答遅延時間 $T_C = 2 \text{ min}$ とし、これを用いて各電力急変データにおける仮想電力制限指令 \widehat{P}_L^b を決定、平常運転データのステップ応答データを得た。

ニューラルネットワークの訓練は、評価用のデータを除外した訓練データを用いて Stacked Autoencoder によりおこなった。訓練は、Modulation 専用試験による訓練データセットと、平常運転時系列から Breakpoint 方式で抽出した訓練データセットをそれぞれ用いた。以後、前者のニューラルネットワークモデルを Modulation モデル、後者を Breakpoint モデルと呼ぶ。

これらモデルについて評価用ステップ応答データ 81 件（2016 年 8 月 18 日の日中 7 時間、5 分毎に P_L^b を変えて計測）を用いて、定格比電力予測誤差率 $E_{W5R}^b [\%]$ や室温偏

表 3.1 実験対象のオフィスビル空調設備の概要

項目	内容
建物用途	一般事務所
規模	2 階建、延床面積約 1600 m ²
ビルマルチ室外機台数	5 台（5 Blocks）
室内機台数	室外機当たり 6 台、合計 30 台
各 Block 定格空調能力	40, 40, 45, 68, 73 kW

差予測誤差 E_{T5}^b [deg]の評価をおこなった。ここで誤差 E_{W5R}^b と E_{T5}^b は、5分間電力量を $W_5^b(m)$ [kWh], 定格5分間電力量を W_{5R}^b として次の式(3.6), 式(3.7)のように定義した。

$$E_{W5R}^b = \frac{\widetilde{W}_5(m) - W_5(m)}{W_{5R}} \times 100 \quad (3.6)$$

$$E_{T5}^b = \widetilde{T}_{SA}^b(t+5) - T_{SA}^b(t+5) \quad (3.7)$$

各誤差の2乗平均平方根値(RMS値)を計算した結果を表3.2に示す。 E_{W5R}^b のRMS値は, Modulationモデルでは10.6%, Breakpointモデルでは14.9%となった。 E_{T5}^b のRMS値は, Modulationモデルでは0.4deg, Breakpointモデルでは0.5degとなった。定格比電力予測誤差率 E_{W5R}^b ではBreakpointモデルの方が5%ほど悪化となるものの, 差は1kW未満であり, RTP適応制御上は問題とならないと考えられる。室温偏差予測誤差 E_{T5}^b では0.1deg悪化している。しかし, それは0.1deg以下であり, 人の体感的にはモデル間に大差ないと考えられる。Breakpointモデルの悪化要因は, 学習データ件数が少なく空調機動作パターンを網羅できていないこと, 電力制限指令が仮定値であることが考えられる。

表3.2 ニューラルネットモデルの予測誤差 RMS 値

項目	Modulation モデル	Breakpoint モデル
定格比電力予測誤差率 E_{W5R}^b [%]	10.6	14.9
室温偏差予測誤差 E_{T5}^b [deg]	0.4	0.5

3.4 RTP 適応制御シミュレーション実験

3.4.1 ビルマルチ空調設備モデル

RTP 適応制御における最終的な評価は実機試験が望ましいが比較の前提となる同一環境の再現、つまり RTP 適応制御前の物理的な稼働環境（ビル空調設備の冷媒流量や人を含むビル内熱源の配置状態、天候等）の再現は困難である。したがって、構築した 2 つの単独 RTP 適応制御用の応答予測ニューラルネットワークモデルの比較のみを目的として、シミュレーション実験をおこなった。

空調機の 1 分毎電力・室温モデルは、先行論文[37]でも使用する式(3.8)の AE (Aircon Emulator) モデルを用いた。

$$\begin{cases} P^b(t+1) = P^b(t) + \Delta P^b(t) \\ T_{Ai}^b(t+1) = T_{Ai}^b(t) + k_{OA}^b (T_O^b(t) - T_{Ab}^b(t)) \\ \quad - k_{OC}^b \frac{C_{Pi}^b \cdot S_{THi}^b}{\sum_{i \in b} C_{Pi}^b \cdot S_{THi}^b} P^b(t) + T_{AE}^b \end{cases} \quad (3.8)$$

このモデルは 2 つの漸化式を連立したモデルであり、式(3.8)の 2 式は、冷媒圧縮機インバータ電力値 $P^b(t)$ が電力制限指令 P_L^b の値に対し $\Delta P^b(t)$ で定率増加・減少するとし、それによる熱収支の変化を表したものである。ここで $\Delta P^b(t)$ は圧縮機インバータ定率増減値 [kW/min]、 $T_{Ai}^b(t)$ は室内機 i における 1 分毎室温 [°C]、 k_{OA}^b は外壁からの貫流熱の係数であり、外壁面積 × 熱還流率である。 k_{OC}^b は空調機効率に関する係数であり、COP を熱容量で除した値である。 C_{Pi}^b と S_{THi}^b はそれぞれ室内機 i の冷房能力とサーキュレーションモード On/Off ステータス (0 または 1)、 T_{AE}^b は内部発熱による室温変化率 [deg] である。これらモデルのパラメータは先行文献[4]と同様に、実機試験データにフィッティングした値を用いた。

3.4.2 シミュレーション実験条件

シミュレーションの条件は、制御総時間が 30 分となるようフレーム数 $m_{max} = 6$ とし、電力単価は 10 分毎に高額(¥100)、中間(¥30)、低額(¥10)のいずれかに変化するものとした。30 分間とした理由は、我が国の電力量評価時間単位[30]であるためである。また、AE でシミュレーションするビル空調設備は表 3.1 に示す 5 つの Block で構成され、室内機は Block 当り 6 台の計 30 台とする。AE のモデルパラメータは全ての Block で同一とし、各室内機の設定室温は 26.0°C 固定、初期室温は 30.0°C、外気温は 32.0°C 固定とした。そのため、応答予測ニューラルモデルも全ての Block で同一である。制御評価関数 J_I^b のバランス係数は $\alpha = 0.1$ とし、室温管理を優先して制御するようにした。

シミュレーションでは、上述の 3 種類の電力単価を網羅するような表 3.3 に示すパターンを設けた。この全パターンについて Modulation モデル・ Breakpoint モデルの 2 つの応答予測ニューラルネットワークモデルでそれぞれシミュレーション実験をおこなった。

このシミュレーション実験結果の例として、図 3.5 に電力単価パターン RP14 の場合を示す。これは 10 分フレームで異なる電気料金単価の組み合わせとなる場合において 30 分間の合計電力料金で最も差がついた例である。この例の Breakpoint モデルは、低額時間帯 ($10 \leq t < 20$; 破線部) に電力制限指令を 14kW まで大きく開放し、電力を使用しても空調能力を増強して室温と設定温度との差を大きく縮めている。その結果、Modulation モデルに対し評価関数 J_I^b の室温ペナルティを小さくすることに成功している。

表 3.3 シミュレーション電力単価パターン

$R(m)$ Pattern	$R(1)$	$R(2)$	$R(3)$	$R(4)$	$R(5)$	$R(6)$
RP1	¥10	¥10	¥10	¥10	¥10	¥10
RP2	¥10	¥10	¥10	¥10	¥30	¥30
RP3	¥10	¥10	¥30	¥30	¥10	¥10
RP4	¥30	¥30	¥10	¥10	¥10	¥10
RP5	¥10	¥10	¥30	¥30	¥30	¥30
RP6	¥30	¥30	¥10	¥10	¥30	¥30
RP7	¥30	¥30	¥30	¥30	¥10	¥10
RP8	¥30	¥30	¥30	¥30	¥30	¥30
RP9	¥10	¥10	¥10	¥10	¥100	¥100
RP10	¥10	¥10	¥100	¥100	¥10	¥10
RP11	¥100	¥100	¥10	¥10	¥10	¥10
RP12	¥10	¥10	¥30	¥30	¥100	¥100
RP13	¥10	¥10	¥100	¥100	¥30	¥30
RP14	¥30	¥30	¥10	¥10	¥100	¥100
RP15	¥30	¥30	¥100	¥100	¥10	¥10
RP16	¥100	¥100	¥10	¥10	¥30	¥30
RP17	¥100	¥100	¥30	¥30	¥10	¥10
RP18	¥30	¥30	¥30	¥30	¥100	¥100
RP19	¥30	¥30	¥100	¥100	¥30	¥30
RP20	¥100	¥100	¥30	¥30	¥30	¥30
RP21	¥10	¥10	¥100	¥100	¥100	¥100
RP22	¥100	¥100	¥10	¥10	¥100	¥100
RP23	¥100	¥100	¥100	¥100	¥10	¥10
RP24	¥30	¥30	¥100	¥100	¥100	¥100
RP25	¥100	¥100	¥30	¥30	¥100	¥100
RP26	¥100	¥100	¥100	¥100	¥30	¥30
RP27	¥100	¥100	¥100	¥100	¥100	¥100

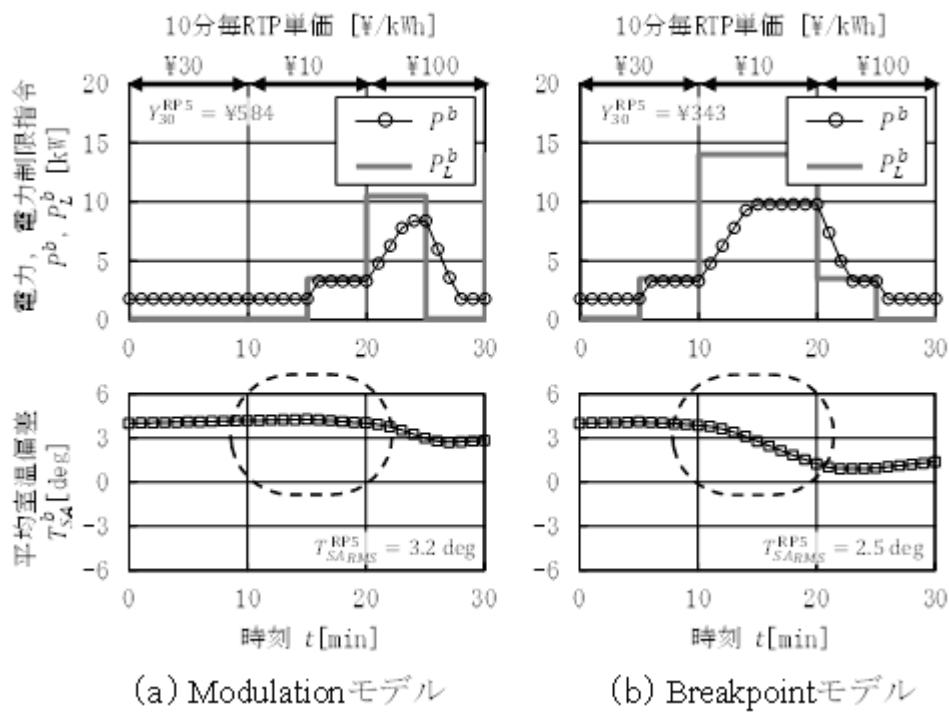


図 3.5 RTP 適応制御シミュレーション実験における電力と室温の時間変化例（電力単価パターン RP14）

3.5 応用サービス上の性能比較

シミュレーションは制御フレーム全体（30分間）における合計電力料金と平均室温偏差の2つのパラメータにより総合評価した。ここで、合計電力料金は換算合計電力料金 $S_{30}(RP)$ [¥]で評価する。換算合計電力料金とは、各電力単価パターン間での結果比較をしやすくするために、平均単価が電力単価パターン RP12 と同一となるような比率を計算し、合計電力料金にかけたものである。室温偏差は2乗平均平方根値（RMS値） $T_{SA_RMS}(RP)$ [deg] で評価する。その理由は、室温偏差が負となり得ること、1°C以下の小さな偏差は体感上大きな差がないことから単純平均では正しく評価できないためである。また、すべての電力単価パターンの平均は、それぞれ S_{30} [¥], T_{SA_RMS} [deg] と表す。
 $S_{30}(RP)$ と $T_{SA_RMS}(RP)$ のレーダーチャートが図 3.6, 図 3.7 であり、中心に近づくほど制御性が優れていることを示す。Modulation モデル（灰色）は、 $S_{30}(RP)$ は ¥448～¥587, $T_{SA_RMS}(RP)$ は 2.9～3.3 deg, Breakpoint モデル（黒色）は $S_{30}(RP)$ は ¥500～¥829, $T_{SA_RMS}(RP)$ は 2.5～2.9 deg となった。

図 3.8 は S_{30} について示したものである。この値は、Modulation モデルでは $S_{30} = ¥523$, Breakpoint モデルでは $S_{30} = ¥685$ となった。つまり、今回の結果では従来方式に対して本方式を使った RTP 制御の合計料金は 30%高い結果となった。

図 3.9 は T_{SA_RMS} について示したものである。それぞれ値は従来方式の Modulation モデルでは $T_{SA_RMS} = 3.0$ deg, 本方式の Breakpoint モデルでは $T_{SA_RMS} = 2.7$ deg となった。つまり、従来方式に対して本方式の方が 10%の温度上昇副作用が緩和する結果となった。

この結果の理由は、当然学習データの収集方法の違いが大きい。3.3節で示したように電力制限指令 P_L^b に対する電力抑制値応答予測 $\widetilde{W}_5(m)$ のモデル精度は Breakpoint モデルの方が 5%悪化しており、これが本方式の電力料金面での性能悪化となった一つの要因だと考えられる。そのトレードオフとして室温面では本方式の方が良い結果となっていながら、室温に与える影響は間接的で効果が小さかつたため、10%程の差異にとどまったのではないかと推測される。

このように電気料金と室温はトレードオフの関係となるため、従来方式と本方式のどちらが良いかはユーザが判断することであり一概に決めるることは出来ないが、本方式は電気料金の上昇幅に対して室温の下降幅が小さいことから、応用サービス上の単純な性能比較では従来方式のモデルの方が良いといえる。ただし、本章では応用サービス上の性能向上ではなく、訓練データ収集方式の改善が主たる目的であるため、次節にてその観点での有用性を検討する。

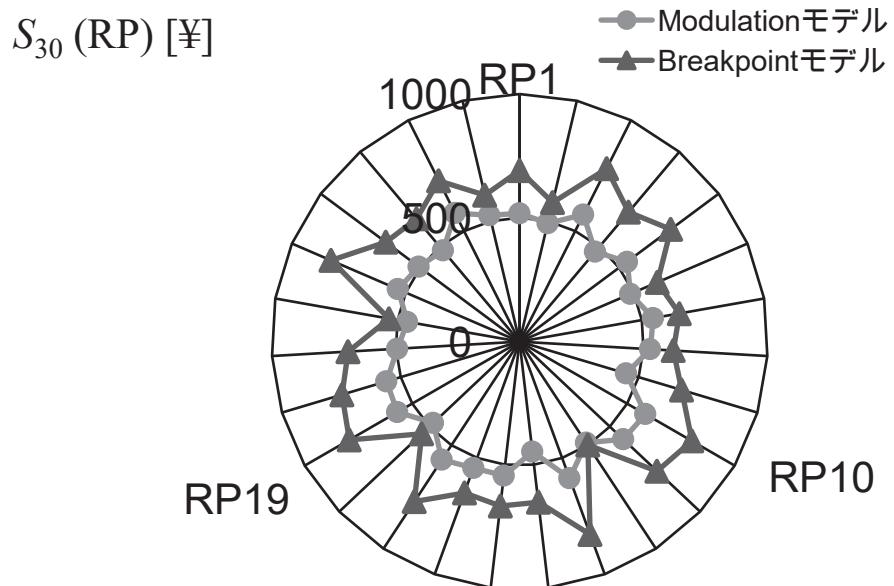


図 3.6 RTP 制御期間 30 分間電力料金 $S_{30}(RP)$ の総合評価

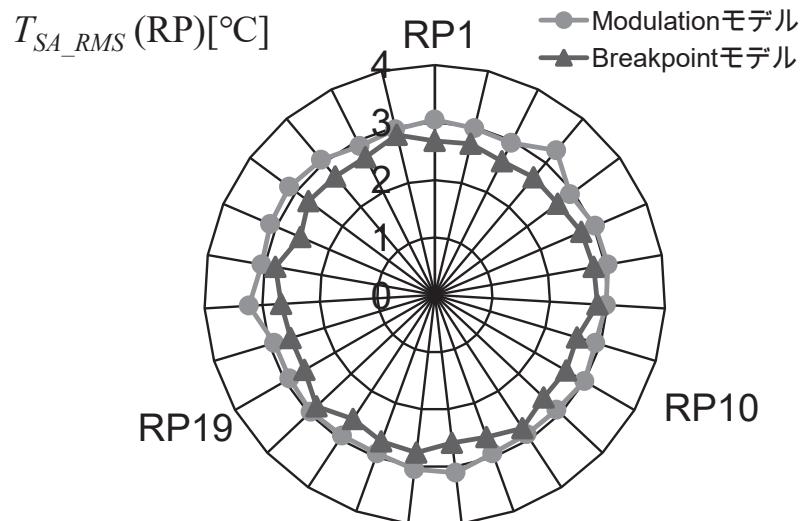


図 3.7 RTP 制御期間 30 分間平均室温偏差 RMS 値 $T_{SA_RMS}(RP)$ の総合評価

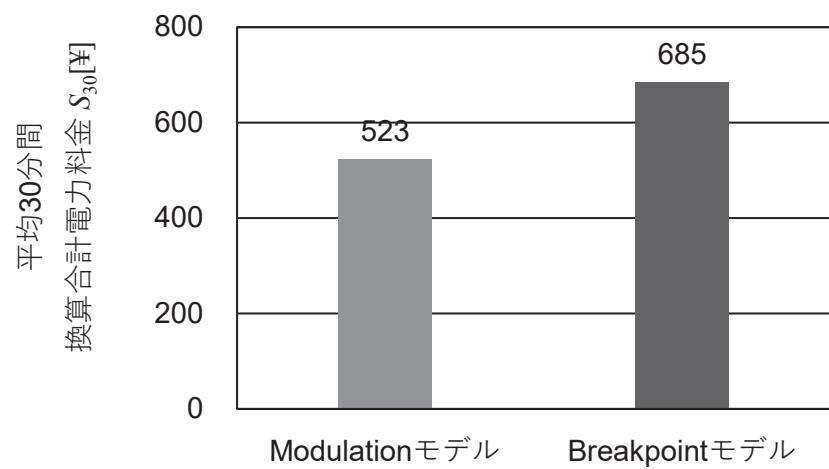


図 3.8 RTP 制御合計電力料金 S_{30} の比較

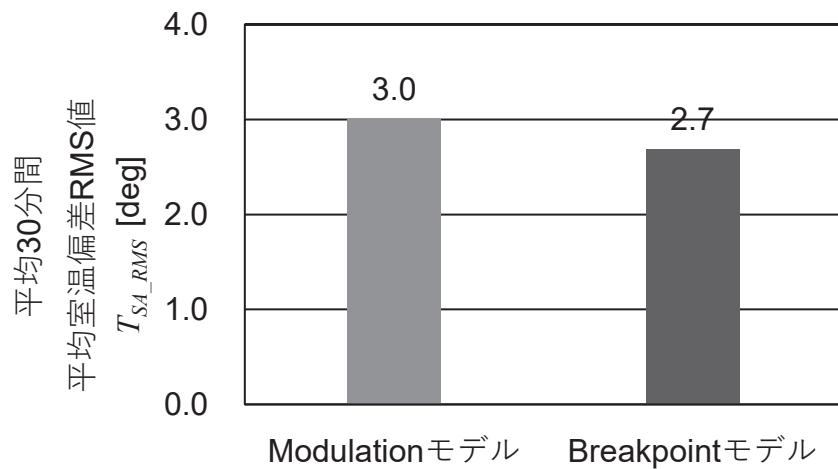


図 3.9 RTP 制御平均室温偏差 RMS 値 T_{SA_RMS} の比較

3.6 応用サービス上の有用性

前節にて応用サービス上の単純な性能比較では従来方式のモデルの方が良いと結論づけたが、応用サービスにおいて本方式には学習データ収集コスト上の大いなるメリットがある。従来方式では専用試験が必要でビル居住者への負担と試験時間の問題が大きいが、本方式では過去収集した平常運転データを用いることでこれらの問題を解決できる。具体的に訓練データの収集コストがどのようになるか、次に検討する。

従来方式（Modulation 方式）と本方式（Breakpoint 方式）の 2 つのモデリングにおいて決定的な違いとなるのは訓練データの収集にかかる時間である。このデータ収集時間に比例してコストは増加すると考えられるので、本章ではこの時間の検討をもって訓練データの収集コストの検討とする。

Modulation 方式では、訓練データ収集時間に電力制限ステップ応答を得るための専用試験をおこなうための試験時間が含まれるが、その試験期間中に応答訓練データを抽出する処理が並行しておこなえるため、抽出時間はほぼ無視できる。

一方 Breakpoint 方式では、過去記録収集した平常時運転データを利用して専用試験は不要で、試験時間は存在しない。しかし、既に記録された平常運転データから訓練データを計算処理するだけの抽出時間は含まれる。この抽出処理は室外機系統 Block 每に実施するものであるから、少なくとも Block 数に比例する時間がかかる。なお、室内機データは計算処理不要のため、室内機数による抽出時間変動は少ないと推測される。そこで本検討では無視する。

本章におけるこれら収集時間を調査・集計したところ、各方式のデータ収集時間は次の表 3.4 で示す結果となった。Modulation 方式では電力制限指令の印加時間合計値、Breakpoint 方式では訓練データ抽出ソフトウェア動作時間の計測である。今回の例でビル空調設備が大規模な場合、例えば Block 数 $b_{max} = 30$ を想定すると Breakpoint 方式の訓練データ収集時間は Modulation 方式の 198 時間にに対して約 4 分の 1 の 51 時間という

表 3.4 訓練データ収集時間の比較

	Modulation 方式	Breakpoint 方式
データ実験時間 [h]	198	≈ 0.0
データ抽出時間 [h]	≈ 0.0	$1.7 \times b_{max}$
計	198	$1.7 \times b_{max}$

注 b_{max} : Block 数

結果となった。

以上より、平常運転データを用いた場合に RTP 適応制御において試験データを用いた場合と同等の制御性が実現できた際、モデル開発時間を削減できる可能性を示す結果が得られた。

3.7 結言

本章では、ビルマルチ空調機 RTP 適応制御における応答予測ニューラルネットワークについて、平常運転時に既に収集してある電力時系列から急変点を抽出して訓練データとしてモデリングする新方式を試行した。

新方式で訓練した応答予測モデルの有効性を検証するため、シミュレーション実験により RTP 適応制御を実施して従来方式と比較検証した。その結果、以下の知見を得た。

- 1) 室温管理優先でのシミュレーション実験では新方式は総電力料金評価で 30%悪化した一方、室温偏差評価では 10%良化した。
- 2) 訓練データ収集時間面では、専用試験を廃止して既存の平常運転時系列から解析のみで訓練データを抽出することで、収集時間を短縮する可能性を示した。

本章の結果では、ビルマルチ空調 RTP 適応制御に関する一連研究の中で、適応制御ニューラルネットモデルの開発を実用的かつ短時間にする可能性を示した。

第4章 機械学習モデルの予測誤差集約均し効果

4.1 緒言

将来のスマートグリッド技術として電力制御指令に対して需要家が分単位で応答する FastADR (Fast Automated Demand Response) が研究されている[63]-[69]。この FastADR における需要家設備として、有望視されているものにビルマルチパッケージエアコン空調設備がある。その理由としては普及率と可制御性が挙げられるが、一方で複雑な冷媒回路の分散型組込み制御となるため、確率的な制御動作となり、数分の応答を問題とする場合はその不確実性が問題となりうる。

ビルマルチ空調設備と同様に個々の装置では不確実性をもつ太陽光発電や風力発電では、大量にアグリゲーション（集積）した時の均し効果によりこの問題の解決が試みられている。しかし、ビルマルチ空調機はオフィスビル群に広範囲に分布しているにも関わらず、大量アグリゲーションにおける均し効果の定量的検討は先行研究[70]のほかには見当たらない。

また電力料金単価によるデマンドレスポンス (DR) については、住宅向けや集中型ビル空調を対象とした研究[71][72]や、料金と快適性のトレードオフ[73]や、短い料金変動への対応[74]等の研究もある。しかし、分散型ビルマルチ空調では、時間単位の遅い制御の研究[75][76]は存在するが、数分単位で精密電力制限する FastADR 応答予測は見当たらない。

本章では、ビルマルチ空調設備電力の大半を占める圧縮機電力を直接分単位で制限する方式による FastADR について、モデル予測と実応答との予測誤差という評価指標で大量アグリゲーションによる均し効果を検討した。

モデル予測と実応答との予測誤差の均し効果は、先行研究[77]-[79]において実機時系列データから構築した多数の数式モデルを用いて、それら大量の予測応答を重ね合せるシミュレーションにより求めた。

4.2 FastADR 機械学習モデル予測誤差の均し効果

4.2.1 FastADR 機械学習モデル予測誤差

前述のように確率的動作の冷媒組込み制御のため、毎回 ($n = 1, 2, \dots, N$) の応答予測値 $P^{b(n)}(t)$ は確率的であり予測モデルと実測値は誤差を生じる。複数回の分刻み応答を重ね合せたアグリゲーション電力 $P_{AG}^b(t)$ は誤差が小さくなると期待できる。

$$P_{AG}^b(t) = \sum_{n=1}^N P^{b(n)}(t) \quad (4.1)$$

今回は、予測モデルおよび実測による電力制限応答を約 100 回 ($N=96$) 重ね合せて相互の誤差を評価した。

図 4.1 は NN モデルを用いて、電力制限応答 96 回を重ね合せ実測値と予測値を比較した図である。次節で示す相対誤差 E_{W5} は NN モデルで 2% と大きく改善された。この結果から、電力制限応答を繰り返し行うことにより、個々の抑制応答の確率的現象による予測の失敗が打ち消し合う可能性を示すことができた。よって、繰り返し電力制限応答を行うことで、その期待値としての誤差は減少する可能性があるといえる。なお FastADR 応答以前から指令と実測値との間に差があるのは、この電力制限指令 P_L は上限を伝えるだけであり実電力は組込み制御に任せたためである。

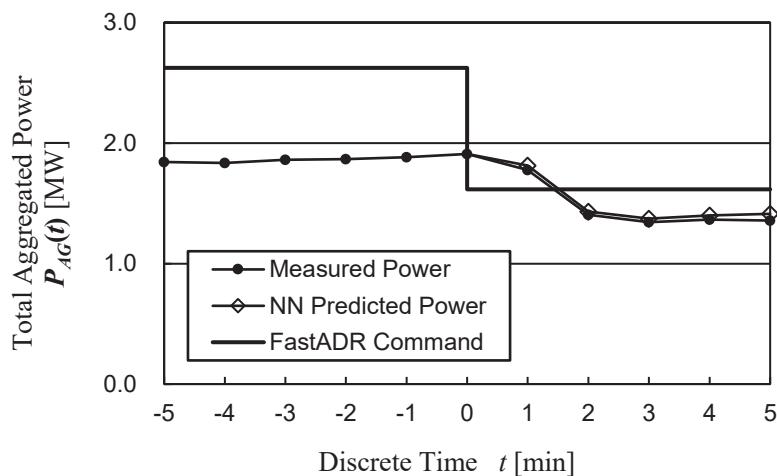


図 4.1 Aggregation of many repetitions of FastADR step responses with model prediction

4.2.2 予測誤差の定義

時刻 $t + \tau$ において、 $\tau = 0$ で電力制限が発令されたとして $\tau = 1, 2, \dots, 5$ の 5 分間電力量の実測値 W_5^b [kWh] とその予測値 \widetilde{W}_5^b [kWh] から次式のようにモデル予測誤差 E_{W5}^b を定義する。

$$\begin{aligned} E_{W5}^b &= (\widetilde{W}_5^b - W_5^b) / W_5^b \\ &= \left(\sum_{\tau=1}^5 \widetilde{P}^b(t + \tau) - \sum_{\tau=1}^5 P^b(t + \tau) \right) / \left(\sum_{\tau=1}^5 P^b(t + \tau) \right) \end{aligned} \quad (4.2)$$

このとき、FastADR 電力制限を $n = 1, 2, \dots$ と N 回繰返すとして、その 5 分間電力量合計 $W_5^{b(N)}$ を N 個重ね合せた合計 5 分間電力量の予測誤差 $E_P^{b(N)}$ を下式で定義する。

$$\begin{aligned} E_P^{b(N)} &= (\widetilde{W}_5^{b(N)} - W_5^{b(N)}) / W_5^{b(N)} \\ &= \left(\sum_{n=1}^N \widetilde{W}_5^{b(n)} - \sum_{n=1}^N W_5^{b(n)} \right) / \left(\sum_{n=1}^N W_5^{b(n)} \right) \end{aligned} \quad (4.3)$$

4.2.3 予測誤差における均し効果

重ね合せる応答波形の数 N 、つまり FastADR 繰り返し回数を増やすことによる予測誤差バラツキの均し効果を調べた。各 N の場合ごとに実現値としては、50 試行のモンテカルロシミュレーションを実施して、予測誤差 $E_P^{b(N)}$ の標準偏差を求めた。

その結果、図 4.2 に示すように N を増やすに従い $E_P^{b(N)}$ の標準偏差が減少した。よく知られているように、均し効果においては標準偏差に関する $1/\sqrt{N}$ 則が有名であるが、今回の結果でも $1/\sqrt{N}$ 則と類似の結果が得られた。また、均し効果は比較的小さい N でも顕著に見られ、 $N=10$ から $N=50$ に増やすだけで標準偏差は約 50 % 減少した。

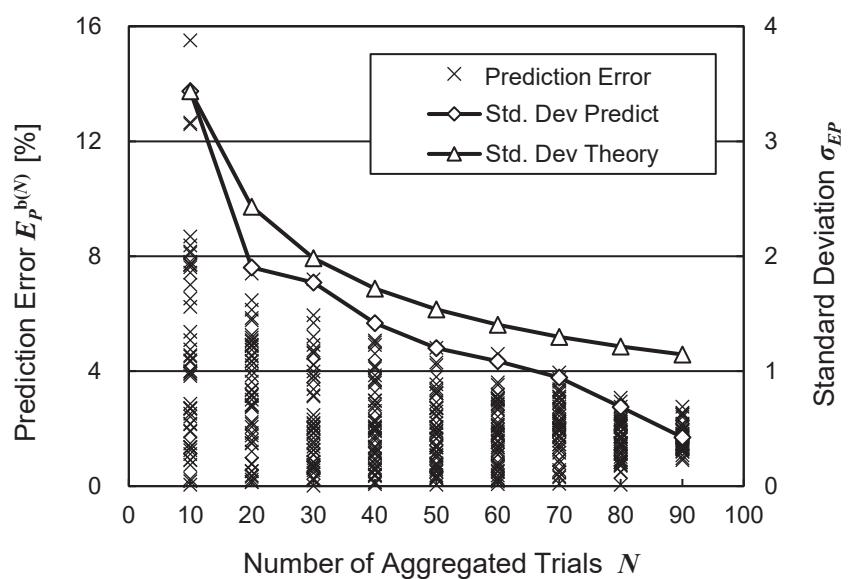


図 4.2 Averaging effect of the FastADR power curtailment predictions

4.3 結言

本章では、実際の室外機 5 台・室内機 30 台のビルマルチ空調設備の FastADR 応答を多
数回繰り返し実測して、大量アグリゲーション時の電力制限応答特性の予測バラツキとい
う観点から均し効果を検討した。そして、FastADR 応答予測モデルによる過渡的な 5 分
後電力の個々予測は困難であるが、約 100 回重ね合せると確率的分布が 2%程度まで減
少し均し効果が確認できた。

本章では、ビルマルチ空調機種や建築設置条件や運転熱負荷などの多様な条件を組合
せた場合における FastADR アグリゲーションの均し効果による確実性向上については
検討していなかった。そこで次章では、そのような多様な条件におけるビルマルチ空調
機の特性について検討をおこなう。

第5章 機械学習モデルの設備多様性

5.1 緒言

近年、脱炭素化などの社会的要請により太陽光発電など再生可能エネルギー電源の導入が加速している。再エネ電源は気象条件により発電量が大幅に変動するため、従来のような発電側だけで行う電力系統の需給バランス調整が困難になってきている。そこで、需要家側からも電力系統の需給バランスを保つように、電力系統からの要請により需要家設備に電力制限を掛けて消費電力量を削減するデマンドレスポンス（Demand Response: DR），さらに、分単位あるいは秒単位で応答する高速自動デマンドレスポンス（Fast Automated Demand Response: FastADR）の導入も検討されている[83]。

このFastADRにおける需要家設備として、有望視されているものにビルマルチ空調機がある。その理由としては、その普及率と優れた可制御性が挙げられる。一方で、図5.1に示すように1台毎のビルマルチ空調機のFastADRに対する消費電力応答は複雑な振る舞いをする。また、個々のビルマルチ空調機がFastADRによって削減できる消費電力量は小さく、需給バランスの調整力としては利用するには、大量な台数をアグリゲーションする必要がある。

前章で大量な台数のビルマルチ空調機のFastADR応答を集約（アグリゲーション）すれば、均し効果により予測誤差は2%程度に減少することを調べた。しかし、この先行研究では単一のビルの実測データを基にビルマルチ空調機械学習予測モデルを作成した

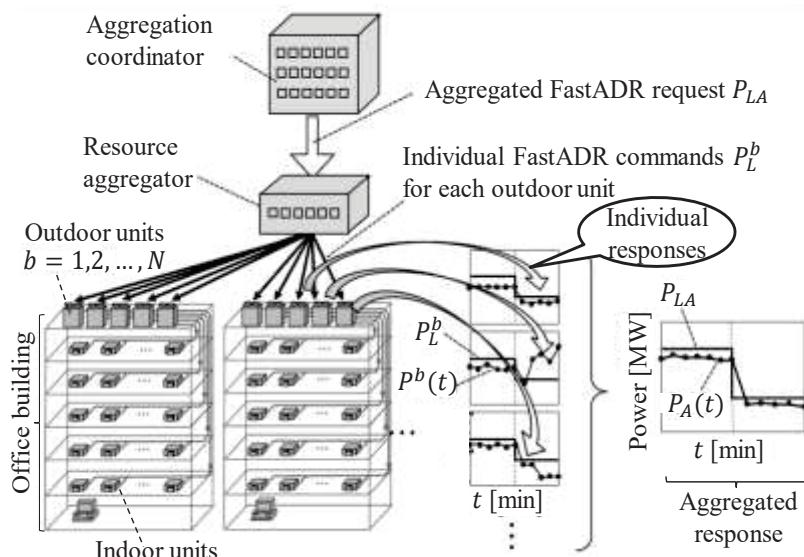


図5.1 ビルマルチ空調FastADRアグリゲーションの概念図

もので、ビルマルチ空調機種や建築設置条件や運転熱負荷などの多様な条件を組合せた場合のFastADRアグリゲーションの均し効果による確実性向上については検討していくなかった。

機械学習予測モデルの訓練データを取得するには、多様なビルマルチ空調に対する大規模・FastADRアグリゲーション応答実験データや平常運転データが通常必要である。しかしながら現実的には困難であるため、本章ではビルマルチ空調エミュレータを用いてデータを取得することを考える。ここで、ビルマルチ空調機のFastADR応答における確率的な動作をあたかも実機のように模擬するものをエミュレータと呼んでおり、先行研究[85][86]で開発したものである。

本章では、この空調機エミュレータに仮想ビルモデル条件、運転条件、気象条件、DR離脱条件等を付与する手法を検討した。そして、熱負荷の異なる2つの時間帯でFastADRアグリゲーション実験をおこない、その多様性を確認した。

5.2 エミュレーションシステム

5.2.1 ビルマルチ空調機エミュレータ

先行研究で、ビルマルチ空調機の複雑な消費電力と室温の動特性を模擬する実時間エミュレータモデル AE (Air-conditioner Emulator) を開発した[85][86]。

AE はビルマルチ空調機 1 台の消費電力 P^b [kW] と各室内機 i 毎の室温 $T_{A_i}^b$ [°C] を以下の差分方程式により Δt [s] 刻みで算出してリアルタイム動作するようモデル化してある。

$$P^b(t + \Delta t) = P^b(t) + D^b(t)\Delta t \quad (5.1)$$

$$T_{A_i}^b(t + \Delta t) = T_{A_i}^b(t) + \frac{dT_{A_i}^b(t)}{dt}\Delta t \quad (5.2)$$

ここで、上付き b は室外機番号、下付き i は室内機番号である。 t は離散時間[s]であり、エミュレーションの刻み幅は $\Delta t = 10[s]$ とする。 D^b は電力変化率[kW/s]であり、電力制限指令値 P_L^b [kW] に対する消費電力 P^b の状態と、後述する温調所要電力 P^* [kW] に対する消費電力の状態から算出する。

温調所要電力 P^* とは、電力制限指令を受けていない条件下で、空調機が本来消費する温調制御上の電力をいう。AE の温調所要電力は、実測データから温調所要電力の決定に寄与する変数を抽出し、重回帰式[87]により近似した。これを(5.3)式で示す。

$$P^*(t) = a_1 T_O(t) + a_2 C_{TH}(t) + B + U_1(\sigma_P^*) + U_2 \quad (5.3)$$

ここで、 T_O は外気温[°C]、 $C_{TH}(t)$ はサーモオン室内機合計容量[kW] であり、 a_1 、 a_2 、 B は重回帰式の係数である。また、 $U_1(\sigma_P^*) + U_2$ は揺らぎ項であり、実機ビルマルチ空調機の組み込み制御による複雑な振る舞いを模擬するために付与したものである。 $U_1(\sigma_P^*)$ は温調所要電力の不確実性を模擬するためのオフセット項であり、 σ_P^* の正規分布とした。 U_2 は空調電力の分単位の揺らぎを模擬するための項であり、一様分布として 1 分毎に更新するものとした。

5.2.2 仮想ビルエミュレータ

先行研究で、ビルマルチ空調エミュレータ AE を複数台組み合わせて仮想ビルエミュレータモデル BEM (Building Emulation Model) を開発した[88]。

図 5.2 にその仮想ビルエミュレータモデルの基本型 BEM1.1 の構成を示す。基本型仮想ビルは 10 階建ての典型的な中型オフィスビルを想定している。基本型仮想ビルの基準階は、中央の間仕切りにより 2 空間に分割されており、この分割された空間を部屋と呼ぶ。各部屋にビルマルチ空調機が 1 つ設置されており、想定用途に応じて異なる空調環境パターンを与えた。

図 5.3 に、1 日の一例の BEM1 運転エミュレーション時系列グラフを示す。この図は同一の熱負荷条件、運転設定条件にして、2 回エミュレーション実験を行った結果である。各 AE の毎回動作が確率的に変動するので、1 試行目と 2 試行目では振る舞いが異なることが分かる。

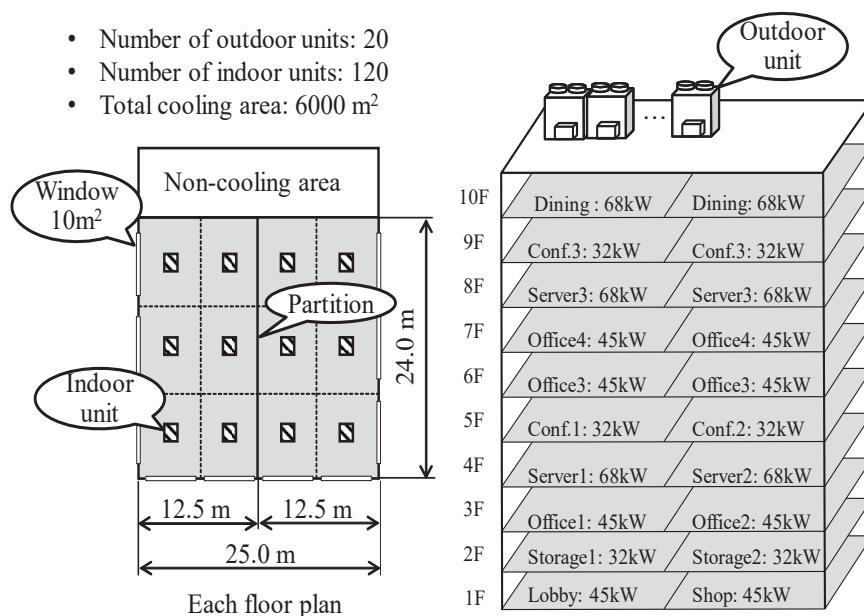
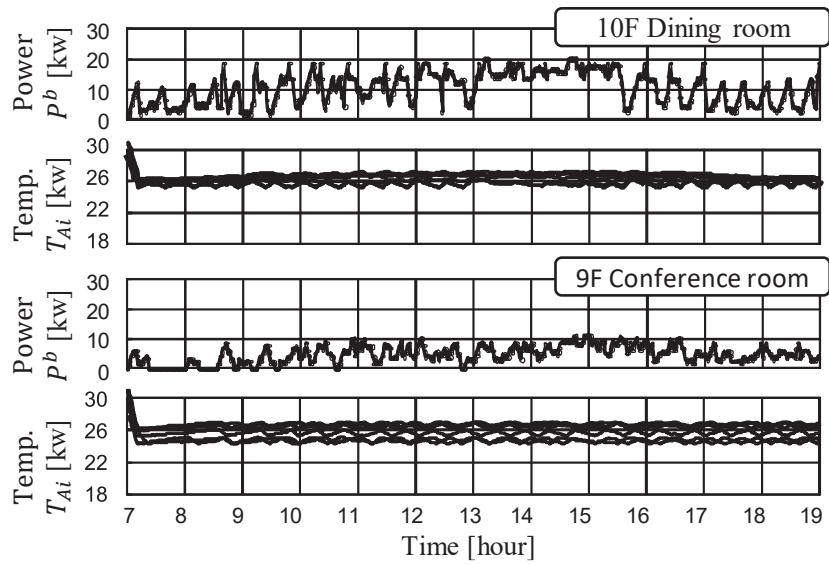
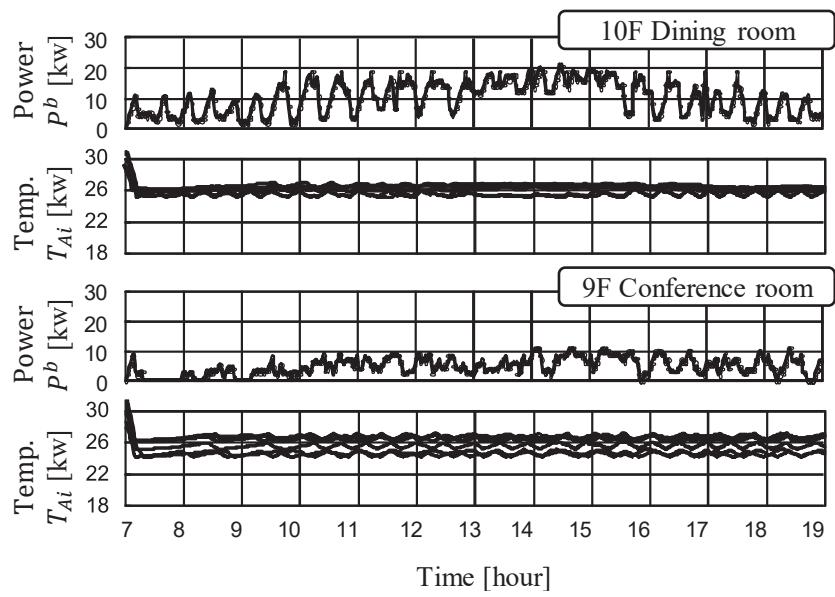


図 5.2 基本形仮想ビルエミュレータ BEM1.1 の構成



(a) 1 試行目



(b) 2 試行目

図 5.3 基本仮想ビル全日エミュレーション時系列

5.3 仮想ビル群の多様性モデリング

5.3.1 仮想ビルの多様性モデル化

一般に、ビル用途によりビルマルチ空調の運転状況に傾向がある。仮想ビル群を用いて、現実的なFastADRアグリゲーションを模擬するには、想定されるビル用途ごとに多種多様のBEMを構築する必要がある。しかし、数百棟ものビルの用途を想定し、1棟1棟BEMを構築することは膨大な時間を要し、現実的に不可能である。

そこで本章では、対象となる仮想ビル群には中型オフィスビル、データセンタービルの2つのビルクラスを想定し、それぞれのビルクラスからビルインスタンスを複数生成することで、仮想ビル群を構築する。同一仮想ビルクラスから生成するビルインスタンスは、空調運転条件がそれぞれ異なるように生成する。表5.1にBEM1.1型（中型オフィスビル型）のビルクラスを作る要件の一覧表を示す。

表5.1 仮想ビル種別の多様性を生成する要件

Building No.c	Building type	BEM type	FloorID	OU No. <i>b</i>	AE type	Room type
1	Medium-sized office building	BEM1.1	1F	1	Type1	Shop
				2	Type1	Lobby
2F			3F	3	Type3	Storage1
				4	Type3	Storage2
3F			4F	5	Type1	Office1
				6	Type1	Office2
4F			5F	7	Type2	Server1
				8	Type2	Server2
5F			10F	9	Type3	Conf. room1
				10	Type3	Conf. room2
:				:	:	:
				19	Type2	Launch room
				20	Type2	Launch room

5.3.2 FastADR 離脱条件の多様性モデル化

同じ仮想ビルにおいて、かつ、同じ運転設定条件でも、そのビル内の区画あるいは執務活動内容によって FastADR に応答しない可能性がある。また、FastADR に応答しても空調機の熱収支により、応答途中に電力制限指令から離脱 (Opt-Out) する可能性がある。

そこで本章では表 5.2 に示すように時々刻々、ビル内の区画と執務活動内容によって、FastADR 離脱条件が変化するように多様性を持たせた。ここで、 $O_{OR}^{c,b}(h)$ は Opt-Out ランクの値をもつ変数であり、FastADR 電力制限による室温上昇上限値 [°C] を表す。上付き c, b はビル c 内の室外機 b を意味する。 h は時間帯番号を示す。

例えば $h = 7$ は 7:00～7:59 の間を意味し、 $O_{OR}^{1,1}(h)$ は 7 時台に 5[°C]、8 時台は 2[°C] といった形で、FastADR 離脱条件である室温上昇上限値が時間帯毎に変化することを表している。これにより、例え同一空調機であっても離脱しやすさが変化するため、多様な FastADR 応答エミュレーションが可能となる。

表 5.2 空調機毎 FastADR 離脱 (Opt-Out) の多様性を生成する要件

Building No. c	OU No. b	Item $O_{OR}^{c,b}(h)$	Time zone number h				
			7	8	..	17	18
1	1	$O_{OR}^{1,1}(h)$	5 deg	2 deg	..	2 deg	2 deg
	2	$O_{OR}^{1,2}(h)$	5 deg	3 deg	..	5 deg	5 deg
	:	:	:	:	:	:	:
	19	$O_{OR}^{1,19}(h)$	5 deg	5 deg	..	2 deg	2 deg
	20	$O_{OR}^{1,20}(h)$	5 deg	5 deg	..	2 deg	2 deg
2	1	$O_{OR}^{2,1}(h)$	0.2 deg	→	..	0.3 deg	→
	2	$O_{OR}^{2,2}(h)$	0.3 deg	→	..	→	→
	:	:	:	:	:	:	:
	19	$O_{OR}^{2,19}(h)$	0.1 deg	→	..	→	0.2 deg
	20	$O_{OR}^{2,20}(h)$	0.2 deg	→	..	→	→
	:	:	:	:	:	:	:

5.4 エミュレーション実験

5.4.1 ビル全体消費電力の定義

時間帯番号 h のある時刻 $t' = 0$ にビル c の各室外機に対してFastADR 電力制限指令 $P_L^b[\text{kW}]$ が発令されたとする。このとき、室外機 b の消費電力を $P^b(t', h)$ とし、ビルの全体消費電力 $P^c[\text{kW}]$ を下式のように定義する。

$$P^c(t', h) = \sum_{h=1}^{20} P^b(t', h) \quad (5.4)$$

ここで、 t' は電力制限開始時刻からの経過時間であり、刻み幅は1[min]である。

また、各室外機に対する電力制限指令値 $P_L^b(t', h)$ をとし、ビルに対する電力制限指令値 $P_L^c(t', h)$ を下式のように定義する。

$$P_L^c(t', h) = \sum_{h=1}^{20} P_L^b(t', h) \quad (5.5)$$

5.4.2 FastADR アグリゲーション実験

リソースアグリゲータモデルからBEM1.1型仮想ビル10棟に含まれる200台のAEエミュレータに対して、30分間のFastADR電力制限指令を出す実験をおこなった。本実験は、FastADR応答重ね合わせの振る舞い・FastADR応答重ね合わせの分単位のバラツキを確認する目的で、AEエミュレータにFastADR離脱条件を設定し、同じ熱負荷条件、空調運転設定条件、FastADR離脱条件でエミュレーションを100回実行した。

9時台にFastADR電力制限指令を出した場合における、それぞれのAEエミュレータの電力制限応答を重ね合わせたエミュレータ実験結果を図5.4に示す。このグラフより、時間経過と共に、AEエミュレータが次々とFastADRから離脱していくため、電力制限値の維持が困難になることがわかる。FastADR応答アグリゲーション値の毎回試行ごとの目標電力からの誤差（オフセットと呼ぶ）は、目標値に対して相対的に時間とともに乖離していく。開始10分後では、オフセットは5%程度であったが、30分後には25%程度に広がっている。もっとも、このオフセットはリソースアグリゲータがその分を元々電力制限指令値に見込んでおけば、ある程度補償することができる。

図5.5は、9時台と14時台にFastADR電力制限指令を出した場合におけるAEエミュレータの合計電力について、1分毎にヒストグラムをプロットしたものである。この図は1分間毎の200台のAEエミュレータの合計電力のバラつきを示しており、FastADR

離脱条件の設定による仮想ビルの多様性を付加する試みにより、合計電力が確率的に変化していることが分かる。

また図 5.5 は、熱負荷が異なる時間帯についてプロットしたものである。図 5.5(a) の 9 時台は熱負荷が低い場合、図 5.5(b) の 14 時台は熱負荷が高い場合に相当する。どちらもともに、DR の継続時間に応じてヒストグラムの幅が 1.5 倍ほど広くなる。この現象は時間の経過とともに Opt-Out する室外機台数が確率的に上昇することに起因し、以下 2 つのメカニズムによって説明できる。1 つ目は、Opt-Out 後の空調機は、電力制限指令値 P_L に一致せず、不確実な温調所要電力 P^* で運転するため、時間経過に伴い合計電力の不確実幅が増すことになる。2 つ目は、Opt-Out により DR に参加する空調機台数が減少すると、均し効果の影響も減少するため、合計電力の不確実幅はやはり増大することになる。

また、図 5.5(b)では、 ΔP^c が図 5.5(a)よりも 1.5 倍ほど早く増加している。一方、 ΔP^c の変動は、図 5.5(a)の方が図 5.5(b)よりも大きい。これは、9 時台より 14 時台の熱負荷が高いため、より多くの室外機が早く Opt-Out するためである。それゆえに、温調所要電力の変動自体は小さくなると考えられる。

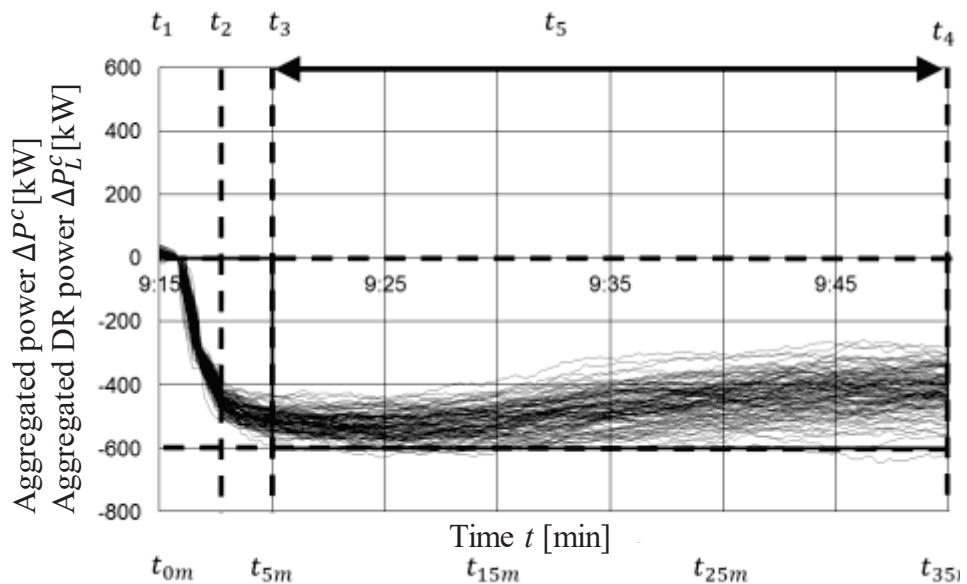
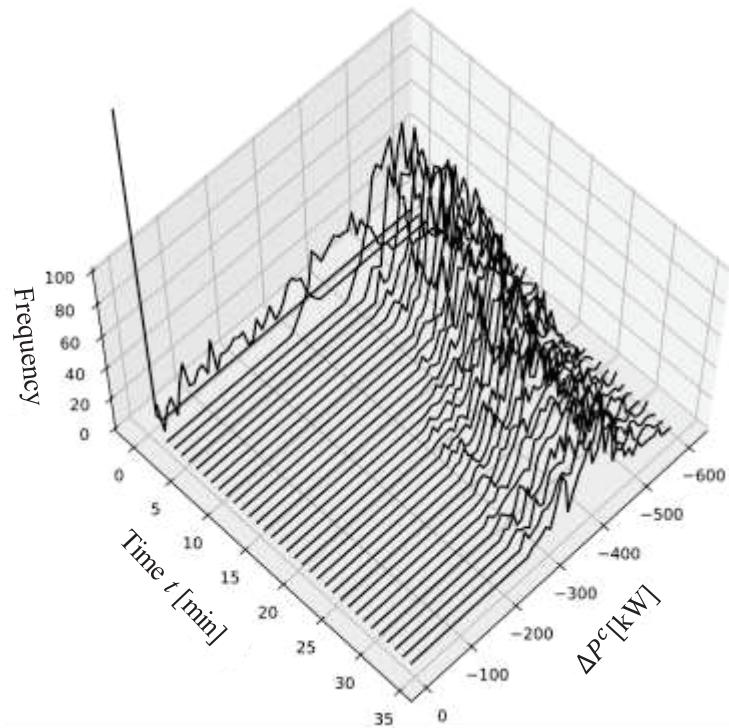
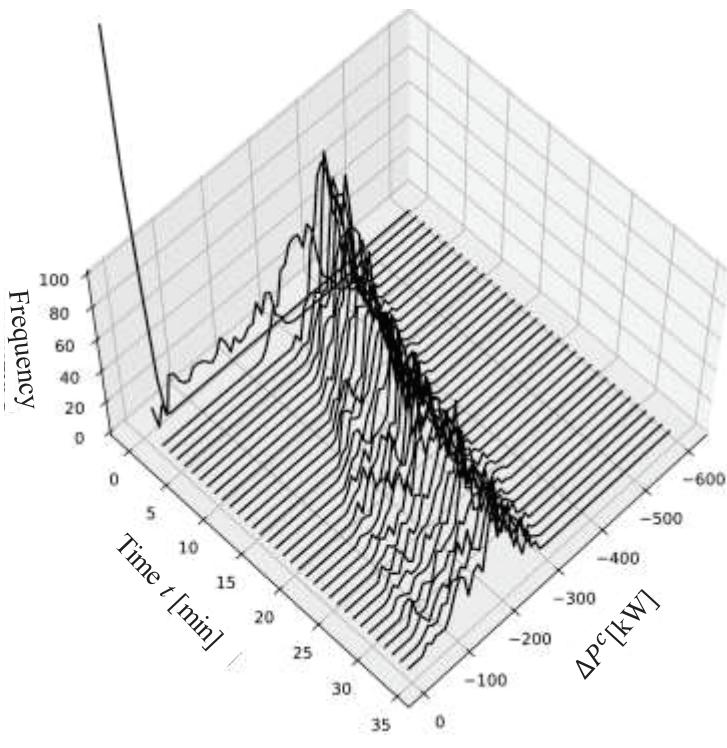


図 5.4 ビル全館 FastADR アグリゲーションのエミュレーション実験



(a) 9 時台



(b) 14 時台

図 5.5 ビル全館 FastADR アグリゲーションにおける合計電力ヒストグラム

5.5 結言

本章では、現実に即したビルマルチ空調機械学習予測モデルの開発を目的として、その訓練データをビルマルチ空調機エミュレータから取得することを考え、エミュレータに空調機の運転条件により多様性を付与する手法を開発した。

具体的には、ビル用マルチエアコン FastADR 応答群の大規アグリゲーション時の確率的特性と時刻依存性をシミュレートするエミュレータを開発した。その開発手法の確認のため、熱負荷の異なる 2 つの時間帯について、ビルマルチ空調 200 台に対する FastADR 電力制限指令を出す実験をおこなった。

第6章 設備電力需要制御の制御残差集約均し効果

6.1 緒言

将来のスマートグリッド技術として電力制御指令に対して需要家が分単位で応答する FastADR (Fast Automated Demand Response) が研究されている[63]-[69]。この FastADR における需要家設備として、有望視されているものにビルマルチパッケージエアコン空調設備がある。その理由としては普及率と可制御性が挙げられるが、一方で複雑な冷媒回路の分散型組込み制御となるため、確率的な制御動作となり、数分の応答を問題とする場合はその不確実性が問題となりうる。

ビルマルチ空調設備と同様に個々の装置では不確実性をもつ太陽光発電や風力発電では、大量にアグリゲーション（集積）した時の均し効果によりこの問題の解決が試みられている。しかし、ビルマルチ空調機はオフィスビル群に広範囲に分布しているにも関わらず、大量アグリゲーションにおける均し効果の定量的検討は先行研究[70]のほかには見当たらない。

また電力料金単価によるデマンドレスポンス (DR) については、住宅向けや集中型ビル空調を対象とした研究[71][72]や、料金と快適性のトレードオフ[73]や、短い料金変動への対応[74]等の研究もある。しかし、分散型ビルマルチ空調では、時間単位の遅い制御の研究[75][76]は存在するが、数分単位で精密電力制限する FastADR 応答予測は見当たらない。

本章では、ビルマルチ空調設備電力の大半を占める圧縮機電力を直接分単位で制限する方式による FastADR について、抑制指令と実応答との制御残差という評価指標で大量アグリゲーションによる均し効果を検討した。具体的には、実ビルマルチ空調設備に対して大量な回数の FastADR 実機実験をおこない、同時発生とみなして応答時系列を重ね合せることで均し効果を定量的に求めた。

6.2 FastADR 重ね合せ実験

6.2.1 応答時系列データ収集方式

一般的にビルマルチ空調設備は設定温度に室温が合うように制御されるため、平常時のデータから、FastADR 電力制限指令が入力された場合に相当する時系列応答データを取得することは難しい。そこで、本章では我々の先行研究で開発した FastADR 電力制限制御方式[38][39][44][80]を用いて、実際のビルマルチ空調設備を遠隔から制御し、時系列応答データを収集した。

応答性を評価するにはビルマルチ空調設備の応答データが一定量必要となるため、中長期的なデータの収集が不可欠だろう。その際、空調設備の利用者との関係性は重要で、その負担は可能な限り軽減するべきだと考える。

この制御方式では、平常時運転中のビルマルチ空調設備に対して遠隔から FastADR 電力制限指令に似た指令を重畠させる。このとき、個々の FastADR 電力制限指令は小信号かつ現在の電力使用レベルを中心にランダムに決定する。この方式であれば有意な室温変化を防ぐことができ、居住者の快適性を損なわないようにしている。またランダムに指令を決定することで、多様なパターンのデータを収集できるようにしている。

図 6.1 に取得した時系列データの例を示す。この例は実際の典型的なオフィスビルのビルマルチ空調設備に対して、5 分毎に FastADR 電力制限指令を出してその応答時系列データを収集したものであり、灰色に示す部分がビルマルチ空調設備の応答時系列データの箇所を示している。

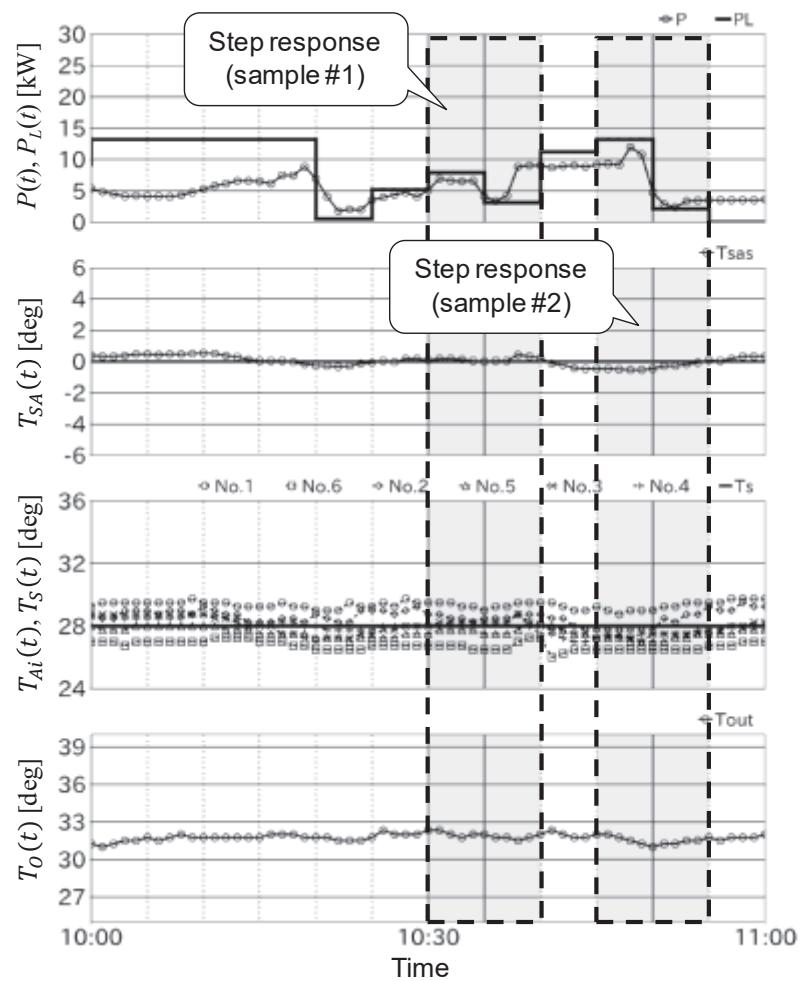


図 6.1 Collection of time-series data of power and temperature responses of FastADR commands.

表 6.1 Outline of a sample office building

Item	Specification
Type of building	General purpose office
Dimension	2 story, area app. 1600 m ²
No. of outdoor units	5 outdoor units
No. of indoor units	6 for each outdoor units, total 30
Rated Cooling Capacity	40, 40, 45, 68, and 73 [kW]

6.2.2 応答時系列データ収集実験

本章で用いる FastADR 電力制限応答時系列データは、ある実際のオフィスビルに対して試験をおこない取得したものである。対象としたのは一般的な小規模オフィスビルであり、エネルギー原単位が全国平均とほぼ同じ、つまり平均的熱負荷特性を有する。また、典型的なエネルギー効率の標準量産品であるビルマルチ空調設備を使用している。

表 6.1 は実験対象のビル空調設備の概要を示す。当該ビルは 30 台の室内機、5 台の室外機からなる空調設備を有す。このビルを用いて 2016 年 8 月の一ヶ月間に、制御間隔を 5 分として先に述べたデータ収集方式を用い、全館空調消費電力 $P(t)$ 、および FastADR 電力制限指令 $P_L(t)$ の 1 分毎時系列データの収集をおこなった。その結果、当該ビルの 5 ブロックのビルマルチ空調機について計 540 回の FastADR 電力制限の応答時系列データを取得した。これらデータには $P_L(t)$ がビル空調設備の最低動作電力以下となるようなサンプル等は除外している。

6.2.3 FastADR 応答の繰り返し重ね合せ集計結果

時刻の異なる数台のビルマルチ空調データを混在させて組合せ合成したものを、多数のビルマルチ空調の同一時刻での合成した応答であると仮定し、FastADR 重ね合せアグリゲーションを検討した。つまり、エルゴート性が成立することを仮定してビルマルチ空調機の実測値によるアグリゲーション電力の検討をおこなった。

N 回のデータの $t \geq 0$ の FastADR 電力制限指令 $P_L(t)$ の合計電力制限指令を P_{LA} とおき、前節で述べた FastADR 応答時系列データ群から P_{LA} の目標値 $5N$ [kW] となる重ね合せ応答時系列データを作成した。この重ね合せ時系列データの作成条件・方法は次の通りである。

- ・ 集積目標値に組合せ結果許容誤差 : $\pm 0.1N$ [kW]
- ・ 組合せの探索方法 : ランダム
- ・ 組合せの探索数 : N 每上限 20 サンプル探索

- ・ 各 N の組合せ：抽出するデータは重複させない
- ・ $N = 1$ の場合：単に条件を満たす時系列データを抽出

このため、 N によって重ね合せ時系列データを作成できた件数は異なっており、例えば $N = 100$ の場合は3ケースしか作成できなかった。

また、重ね合せ時系列データの評価には、以下の式で定義する5分間電力量に基づく制御残差 R_C を用いた。

$$R_C = \left(\sum_{t=0}^4 P_{AG}(t) - \sum_{t=0}^4 P_{LA} \right) / \sum_{t=0}^4 P_{LA} \quad (6.1)$$

各 N のサンプルセットの R_C が分布する平均を μ 、標準偏差 σ とした正規分布を今後分布とする。

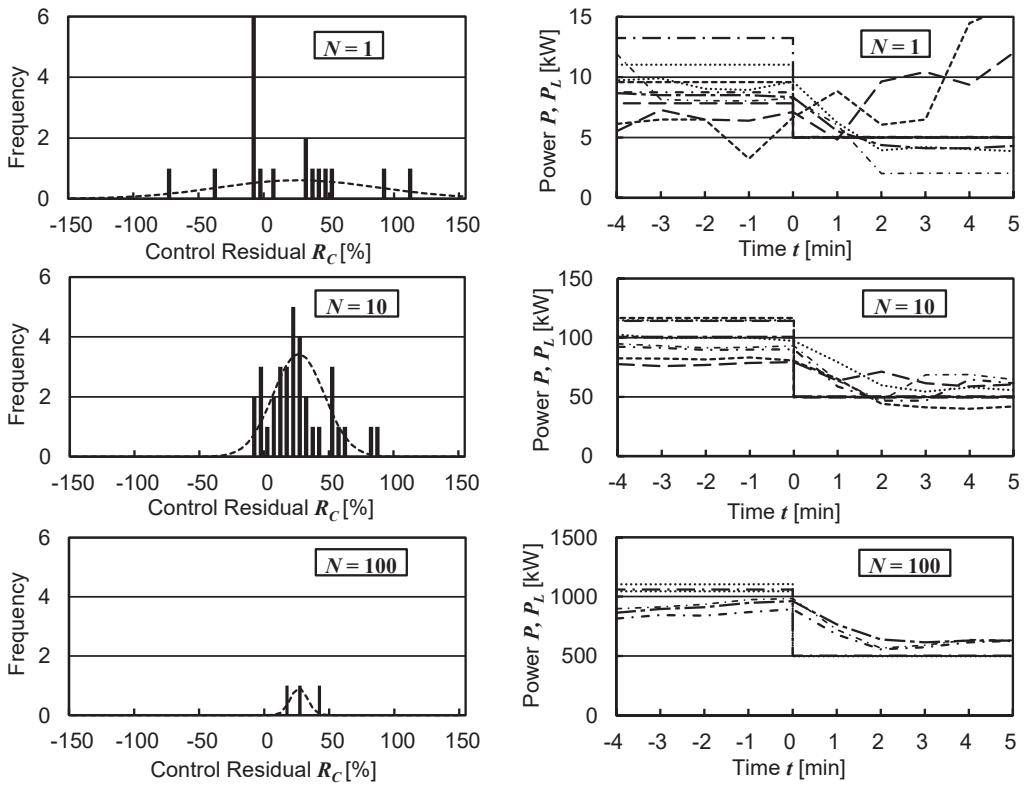
6.3 FastADR 組合せアグリゲーション推定

6.3.1 FastADR 組合せアグリゲーション推定

$N = 1, 10, 100$ のときの R_C のヒストグラムと、重ね合せ応答時系列データの代表例をプロットしたものを図 6.2 に、 $N = 1, 10, 20, 50, 100$ に対する R_C の変化をプロットしたものを図 6.3 に示す。ここで各図の破線は先に述べた均し効果の $1/\sqrt{N}$ 則に基づく理論値（分布／平均 μ とバラツキ $\mu \pm \sigma$ の範囲）を示している。

重ね合せ時系列データのうち、明らかに正規分布ではない $N = 1$ の場合と、サンプルセット数が 3 セットしかなく分布の判断が困難な $N = 100$ の場合を除くと、その分布は極端に外れることではなく全て中心付近に集まっている。 $N = 10$ の場合、図 6.2 のヒストグラムを見ると正規分布に近い結果を得ている。 $N = 20, 50$ の場合も同様であり、制御残差 R_C でも $1/\sqrt{N}$ 則と類似の結果が得られた。

すなわち、FastADR 応答重ね合せにおいて各応答で確率的に生じている抑制目標値に対するバラツキ残差は、重ね合せ数 N が大きくなるとオフセット値としてある値に収束することが分かった。今回の結果に基づけば、例えば R_C のバラツキ $\sigma \leq 5\%$ を目標とした場合 $N \approx 200$ でよいことが分かる。この場合も R_C は $\mu \approx 20\%$ 程度、つまり 1[MW] 程度の固定的な制御残差（オフセット）が存在することになる。



(a) Histogram with normal distribution reference (b) Aggregated step responses
 図 6.2 Distributions of FastADR control residuals and FastADR aggregated step responses

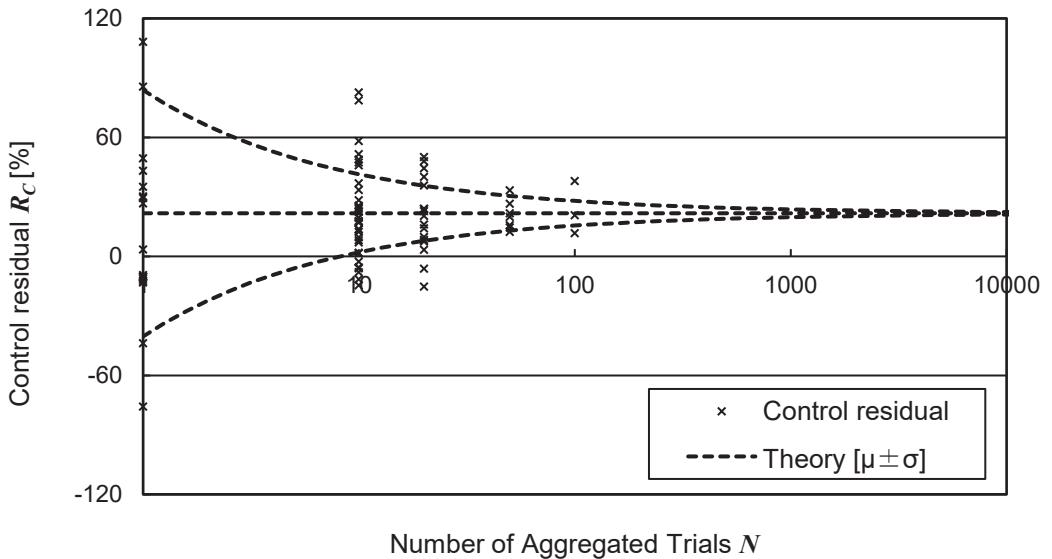


図 6.3 Averaging effect of the variations of the FastADR power curtailment using superimposition of measured data

6.3.2 LNG 火力 EDC モードとの応動速度比較

FastADR 重ね合せアグリゲーションによる多数のビルマルチ空調機のFastADR 出力抑制は、ネガワット発電であると考えることが出来る。そこで試しに、LNG 火力発電設備における EDC モードの応答特性と応動速度の比較をおこなった。

$N = 100$ における FastADR 重ね合せ時系列データにおける電力減少分をネガワット発電とみなし、電気学会「電力需給周波数シミュレーションの標準解析モデル」[81] AGC30 に含まれる 70 万 kW 級 LNG 火力発電設備の EDC 応答波形例と比較したものが図 6.4 である。 $N = 100$ であっても 0.5[MW]程度のネガワットにしかならないため、火力発電設備の応答波形例とは単純に比較ができないが、指令値がそれぞれに設定してから目標値に達するまでの時間はどちらも 2~3 分程度であり、時間的な応答性はよく似ている。

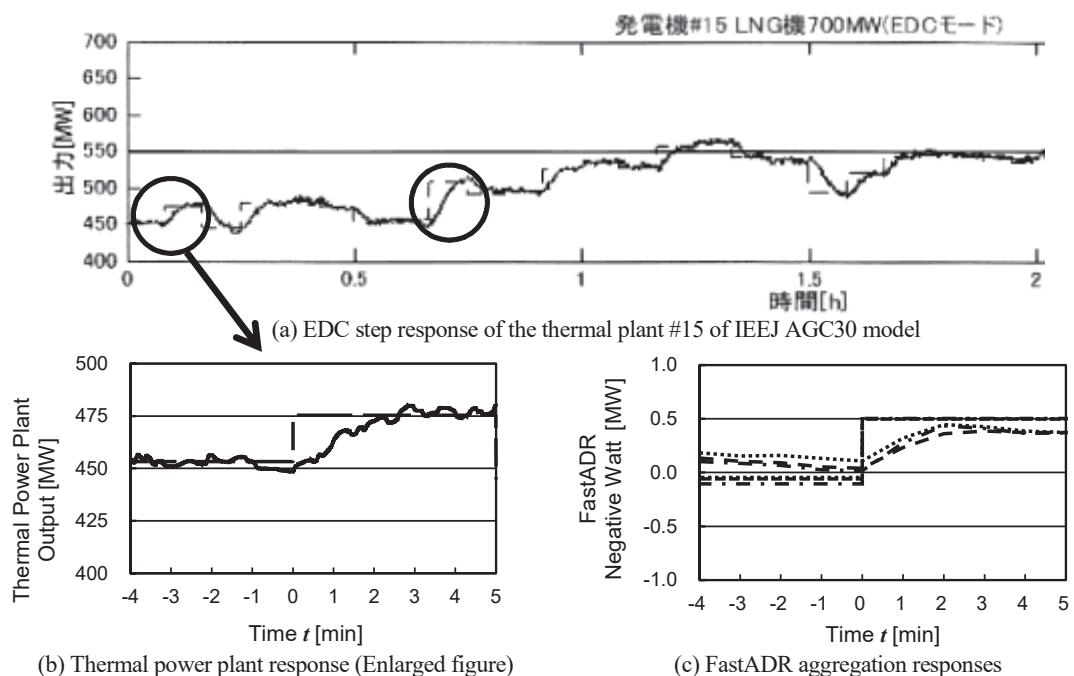


図 6.4 Comparison of a LNG thermal power plant sample and FastADR negative watt samples.

6.4 アグリゲーション予測誤差と制御残差

第4章並びに本章では、実際の室外機5台と室内機30台のビルマルチ空調設備の繰り返しFastADR電力制限を繰り返して、大量アグリゲーション時の組合せ応答特性の予測可能性とバラツキ均し効果を検討してきた。図6.5はモデル予測と実応答との予測誤差 E_P と、抑制目標と実応答の制御残差 R_C という二つのファクターが存在することを図示したものである。

今回はFastADRアグリゲーション抑制目標値となるよう各空調機に個別電力制限指令を単純に割当てて指令した。その結果、アグリゲーション台数が多くなるに従って応答整定後の制御残差（オフセット）現れてくることを示すことができた。これは単純に開ループ制御のためで閉ループ制御をかけば改善される可能性がある。

しかし、我々の先行研究[65]-[67]の結果からFastADR閉ループ制御は広域通信遅れやFastADR手続きなどの無駄時間や閉ループ制御器の設計によっては安定性が問題となる可能性が分かっている。一方、本章で示したように大量アグリゲーションすれば応答合計値のバラツキは収束していく。従って、本章で述べた大量アグリゲーションにおける応答集積値を定量予測できれば開ループ制御でも実用上の要求精度が満足される可能性もある。本研究で新規に発見したこの知見は将来のFastADRアグリゲーション制御システム設計上有用と思われる。

大量アグリゲーション時の予測誤差バラツキの均し効果と制御残差は統計理論により定量的に扱えることが、将来のビルマルチ空調設備群のFastADRアグリゲーションシステム設計上のキーポイントとなると思われる。

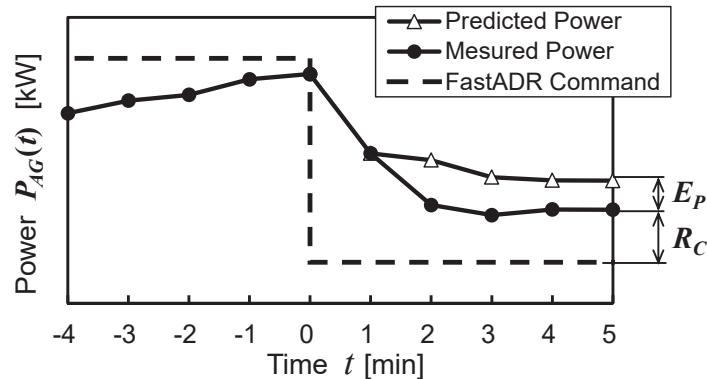


図6.5 Definition of evaluation factors.

6.5 結言

本章では、実際の室外機 5 台・室内機 30 台のビルマルチ空調設備の FastADR 応答を多數回繰返し実測して、大量アグリゲーション時の電力制限応答特性の制御残差という観点から均し効果を検討した。

実測時系列データを目標電力制限量となるようランダム抽出して重ね合せて大量の組合せアグリゲーションにおける均し効果の推定を行った。加えて FastADR アグリゲーション電力制限を高速ネガワット発電であると考え、LNG 火力発電設備における中央給電指令所からの 5 分間隔 EDC 信号への応答速度特性と比較した。以上の検討から、FastADR 応答重ね合せにおいて抑制目標値に対する制御残差は、重ね合せ数 N が十分大きくなると 20%程度の定常オフセット値として出現することが分かった。

第7章 結論

本研究では、主にビルマルチ空調機械学習モデルによる電力需要制御システムにおけるシステム構築面での課題の検討をおこなった。

本研究の成果は以下のとおりである。

- ① ビルマルチ空調機械学習モデルを構築する際に必要となる訓練データについて、平常運転時に既に収集済みの電力時系列から急変点を抽出することで生成する新方式を開発した。その評価のために従来方式で作成した機械学習モデルとの設備電力需要制御システムにて比較検証をおこなった。新方式の有用性までは示すことが出来なかつたものの、開発期間の短縮が実現する可能性を示した。
- ② 機械学習モデルによるビルマルチ空調機設備電力需要制御システムにおいて、予測バラつきについて約 100 回のアグリゲーションにより確率的分布が 2%程度に抑制できる可能性を示した。
- ③ ビルマルチ空調機設備の運転条件により、多様な確率的特性と時刻依存性をエミュレータに付与する方法を開発した。ビルマルチ空調機設備電力需要制御システム(空調機 200 台)の大規模アグリゲーション時において、熱負荷の異なる 2 つの時間帯において多様性のある結果を得た。

以上の成果は、ビルマルチ空調機会学習モデルを用いた設備電力需要制御システムの推進に寄与するものであり、工学的に有用である。

謝辞

本研究を推進するにあたり、大変親身なご指導と励ましを賜りました岐阜大学工学部スマートグリッド電力制御工学共同研究講座の蜷川忠三特任教授に感謝致します。

本論文の審査過程において、数々の御助言と御指導を賜りました岐阜大学工学部電気電子・情報工学科の石川裕記教授と高野浩貴准教授に感謝致します。

ビルマルチ空調機の実機試験ならびにエミュレータ構築にあたり数々の御支援を頂いた、三菱重工サーマルシステムズ株式会社の大嶽宏之様、近藤成治様、稻葉隆様、森川純次様、五十住晋一様、加藤隆博様に感謝致します。

いつも親切に御助言をいただいた、岐阜大学工学部スマートグリッド電力制御工学共同研究講座の青木佳史特任助教、松川瞬元特任助教、有限会社ソリッドの山田倫久博士に感謝致します。

蜷川研究室卒業生の近藤眞示さん、中村惇志さん、大学院生の後藤聰さん、筒井大斗さん、Asif Iqbal さんの他、同研究室の方々には多くの知識や示唆をいただきました。感謝致します。

最後になりますが、本研究及び博士課程の修了に関して、私の勤務する株式会社インターリンクより様々にご支援・ご助力をいただきました。株式会社インターリンクの中尾明一郎会長、森尚久社長、三谷厚子専務の他、全ての皆様にこの場を借りて深くお礼申し上げます。

論文目録

(1) 学位論文の基礎となる学術論文

- ① 鈴木啓太, 蜷川忠三, 森川純次, 稲葉隆, 近藤成治:「実機計測に基づくビルマルチ空調群 DR 過渡応答大量アグリゲーション均し効果の推定」, 電気学会論文誌 B, Vol.138, No.7, pp.582-590, Jul. 2018 (査読あり)
- ② 鈴木啓太, 青木佳史, 蜷川忠三, 森川純次, 近藤成治, 大嶽宏之:「リアルタイム電力料金に適応するビルマルチ空調機群優先エリア複合制御の応答予測ニューラルネットモデル: DNA 解析法と仮想電力制限指令による訓練データ収集方式の評価」, 空気調和・衛生工学会論文集, No.277, pp.1-9, Apr. 2020 (査読あり)
- ③ K. Suzuki, A. Iqbal, Y. Aoki, C. Ninagawa, J. Morikawa: "Stochastic Characteristics of Large-scale FastADR Aggregation Discovered by Using Diverse Building Air-conditioner Emulators", IEEE International Symposium on Industrial Electronics, ISIE 2021, Kyoto, Japan, Jun. 2021 (査読あり)

(2) 参考論文

- ④ K. Suzuki, C. Ninagawa: "Communication Characteristics of Smart Grid ADR Aggregation for Building Facility Power Consumption", 11th International Workshop of Institute of Electrical Installation Engineers of Japan, Osaka, Japan, pp.545-552, Jul. 2013 (査読あり)
- ⑤ S. Miyagawa, K. Suzuki, C. Ninagawa: "Metering Data Transmission Simulation for Smart Grid AMI System with Random Arrangement Model", 11th International Workshop of Institute of Electrical Installation Engineers of Japan, Osaka, Japan, pp.1-6, Jul. 2013 (査読あり)
- ⑥ K. Suzuki, C. Ninagawa, H. Yoshida, S. Kondo, J. Morikawa, T. Kanbe, T. Aoki: "Smart Grid ADR Aggregation Delay Model on Large-Scale Distributed Building HVAC Facilities", IEEE International Conference on Innovative Smart Grid Technologies, ISGT Europe 2013, Lyngby, Denmark, pp.1-6, Oct. 2013 (査読あり)
- ⑦ 鈴木啓太, 蜷川忠三:「ビル空調設備群の大規模アグリゲーションによるデマンドレスポンス制御時間応答」, 電気学会生産設備管理研究会, PFC-14-008, pp.39-44, Jan. 2014 (査読なし)
- ⑧ C. Ninagawa, T. Iwahara, K. Suzuki: "Enhancement of OpenADR Communication for Flexible Fast ADR Aggregation Using TRAP Mechanism of IEEE1888 Protocol", IEEE International Conference on Industrial Technology, ICIT 2015, Seville, Spain, pp.2450-2454, Feb. 2015 (査読あり)
- ⑨ C. Ninagawa, K. Suzuki, A. Nakamura, J. Morikawa: "Applying DNA Analysis Method to Training Data Mining for FastADR Response Model of Air-Conditioning Power Consumption", IEEJ Transactions on Electrical and Electronic Engineering,

Vol.12, No.3, pp.440-441, Dec. 2016 (査読あり)

- ⑩ T. Yamada, K. Suzuki, C. Ninagawa: “Scalability Analysis of Aggregation Web Services for Smart Grid Fast Automated Demand Response”, IEEE International Conference on Industrial Technology, ICIT 2018, pp.1285-1289, Lyon, France, Feb. 2018 (査読あり)
- ⑪ 山田倫久, 鈴木啓太, 蟻川忠三:「ビル設備群デマンドレスポンスの広域アグリゲーション Web サービスのスケーラビリティ解析」, 電気学会論文誌 C, Vol.138, No.5, pp.405-412, Apr. 2018 (査読あり)
- ⑫ 筒井大斗, 鈴木啓太, 蟻川忠三, 森川純次, 大嶽宏之:「多様なビルマルチ空調 FastADR 応答群の大規模アグリゲーションの統計的特性」, 電気学会システム／スマートファシリティ合同研究会, ST-20-040／SMF-20-039, No.30-41, pp.30-44, Nov. 2020 (査読なし)

(空白ページ)

付録

付録A Breakpoint アルゴリズム

A. 1 Breakpoint アルゴリズムの概要

Breakpoint アルゴリズムは遺伝子コピー数の出現確率分布を正規分布 $N(\mu_j, \sigma^2)$ と仮定して、異なる分布に分割できるセグメント分割点（Breakpoint）をベータ分布で推定するものである。そして、先述の通りモデル化した場合における最適な分割点位置の導出を組み合わせ最適化問題とみなして、Cross-Entropy 法により求めるものである。このアルゴリズムの具体的な流れを第 3 章の図 3.2 に示す。この詳細は参考文献[41]に譲り、本付録では主要な概要のみを述べる。

Cross-Entropy 法は、ある分布に基づき取りうる解をいくつか生成・評価をおこない、その評価値が高い解を用いて分布のパラメータを更新するという一連の流れを繰り返すことによって近似解を得るものである。

この Breakpoint アルゴリズムでは、 N 箇所の分割点位置ベクトル $\mathbf{C} = (c_1, c_2, \dots, c_N)$ が Cross-Entropy 法の解に該当する。分割点位置ベクトル \mathbf{C} は観測データベクトル \mathbf{V} のいずれかに対応するため、 j 番目の分割点位置 c_j は $1 < c_j < L + 1$ を満たす。そこで、ベータ分布 $f(\theta; \alpha, \beta)$ の定義域 $[0, 1]$ を $[1, L]$ に拡張した分布である、4 パラメータのベータ分布 $f(v; \alpha, \beta, 1, L)$ を分割点の確率分布として仮定し、その位置 c_j を生成する。4 パラメータベータ分布 $f(v; \alpha, \beta, L_0, L_M)$ の確率密度関数は式(A.1)のように示すことができる。

$$f(v; \alpha, \beta, L_0, L_M) = \frac{f(v; \alpha, \beta)}{L_M - L_0} = \frac{(v - L_0)^{\alpha-1}}{\text{Beta}(\alpha, \beta)} \cdot \frac{(L_M - v)^{\beta-1}}{(L_M - L_0)^{\alpha+\beta-1}} \quad (\text{A.1})$$

ここで Beta(α, β) はベータ関数、 $[L_0, L_M]$ は定義域、観測データは v である。

また、4 パラメータベータ分布により生成した分割点位置 c_j の評価スコアは、以下の式(A.2)で示す修正ベイズ型情報量規準 (mBIC : Modified Bayesian Information Criteria) [42] を用いる。

$$\begin{aligned} \text{mBIC} &= \log \frac{p(M_N | \mathbf{V})}{p(M_0 | \mathbf{V})} \\ &= \left(\frac{L - N + 1}{2} \right) \log \left[1 + \frac{SS_{bg}(\tilde{\mathbf{C}})}{SS_{wg}(\tilde{\mathbf{C}})} \right] + \log \left[\frac{\Gamma\left(\frac{L - N + 1}{2}\right)}{\Gamma\left(\frac{L + 1}{2}\right)} \right] + \frac{N}{2} \log(SS_{all}) \\ &\quad - \frac{1}{2} \sum_{i=1}^{N+1} \log n_i(\tilde{\mathbf{C}}) + \left(\frac{1}{2} - N \right) \log(L) \end{aligned} \quad (\text{A.2})$$

ここで、 $p(M | \mathbf{V})$ は \mathbf{V} の条件下で M が出現する確率密度関数、 M_N は分割点の数が N 個の場合の正規分布モデル群、 M_0 は分割点の数が 0 個、つまり一体の場合の正規分布モデル群である。 $\tilde{\mathbf{C}}$ は分割点位置ベクトル \mathbf{C} の予測値であり $SS_{bg}(\tilde{\mathbf{C}})$ と $SS_{wg}(\tilde{\mathbf{C}})$ の商を最大と

するもの, $SS_{bg}(\tilde{\mathbf{C}})$ は分割された場合の対象確率変数 ν_i の平均からの偏差平方和
 $(\sum_{i=1}^{N+1} n_i(\bar{\nu}_i - \bar{\nu})^2)$, SS_{all} は一体の場合の全体偏差平方和 $(\sum_{i=1}^L (\nu_i - \bar{\nu})^2)$, $SS_{wg}(\tilde{\mathbf{C}})$ は
それらの差 $(SS_{all} - SS_{bg}(\tilde{\mathbf{C}}))$, $\Gamma(t)$ は通常のガンマ関数である。

付録B 大量アグリゲーション時の統計理論の検討

B. 1 中心極限定理の考察

大量アグリゲーション時の統計理論の扱いは重要である。統計学でいう中心極限定理とは、母集団平均が μ 、母集団分散が σ^2 の確率変数 x は、それが正規分布でなくても標本和 $\sum_{n=1}^N X_n$ （あるいは標本平均 $(\sum_{n=1}^N X_n)/N$ ）の N が大きくなると正規分布に近づくという定理である。標準正規分布となるよう変数変換した次式として示される[82]。

$$\begin{aligned} & \lim_{N \rightarrow \infty} \Pr \left\{ x_a \leq \left(\sum_{n=1}^N X_n - N\mu \right) / (\sqrt{N}\sigma) \leq x_b \right\} \\ &= \Phi(x_b) - \Phi(x_a) \\ &= \int_{x_a}^{x_b} \frac{1}{\sqrt{2\pi}} \exp \left[-\frac{x^2}{2} \right] dx \end{aligned} \quad (\text{B.1})$$

ここで、 x_a と x_b は実現値の指定範囲、 $\Phi(x)$ は標準正規分布 $N(0,1)$ の累積分布関数を表す。これを m 番目のビルにおけるFastADR電力量の n 回目の繰返し実現値 $W_m^{(n)}$ に適用する。個々の実現値は正規分布でなくても、その繰返し標本和 W_{AG} は N が大きくなるに従い正規分布に近づくことを意味している。

繰返し実現値を数式モデル予測値 $W'_m^{(n)}$ で計算すると、

$$W_{AG} = \sum_{m=1}^M W'_m^{(n)} \quad (\text{B.2})$$

$$\begin{aligned} & \lim_{N \rightarrow \infty} \Pr \left\{ W_{AGa} \leq \sum_{m=1}^M W'_m^{(n)} \leq W_{AGb} \right\} \\ &= \int_{W_{AGa}}^{W_{AGb}} \frac{1}{\sqrt{2\pi}\sqrt{N}\sigma_W} \times \exp \left[-\frac{(W_{AG} - N\mu_W)^2}{2N\sigma_W^2} \right] dW_{AG} \end{aligned} \quad (\text{B.3})$$

と表される。これは標本和平均が $N \cdot \mu_W$ 、標本和分散が $N \cdot \sigma_W^2$ の正規分布である。ここで、 μ_W および σ_W^2 は元々の $W_m^{(n)}$ の分布における平均値及び分散である。

繰返し標本平均についても中心極限定理が成り立ち、繰返し平均はそのもの、繰返し標本平均の分散は正規分布に近づく。これは、第4章においてFastADR電力量の予測において繰返し標本平均をとることで予測誤差 $E_p^{b(N)}$ のバラツキ標準偏差の減少率が \sqrt{N} に近づいていくことと対応していると思われる。つまり予測誤差の標準偏差の減少率が \sqrt{N}

に近づいていったことが、中心極限定理にあてはまっている。これは第6章で述べた制御残差 R_C においても同様である。

B.2 エルゴート性の考察

第6章に示すようにFastADRの個々の重ね合せ確率分布を調べた。それが同時組合せの重ね合せであるアグリゲーション値の確率分布とみなせる、あるいは少なくとも定量的関係が導き出せればFastADRアグリゲーション開発上有用であろう。

確率的に動作する多数の事象について、群の組合せ平均は個々の繰返し平均と等しいという意味でエルゴート性という。エルゴートという言葉は統計物理学や確率過程理論などその学問分野により異なる意味に使われているが、工学的な問題では、組合せの個体数が大きく観測が困難な場合、少ない個体数の繰返し標本平均で近似できる場合を意味する。

エルゴート性の確率過程 $x^{(k)}(t)$ からみた条件は、 k を個体番号、ベクトル $\mathbf{x}(t)$ を個体集合、 $g()$ を任意関数、 $E[]$ を組合せ平均として下式で表される。

$$\lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T g\left(x^{(k)}(t), x^{(k)}(t + \tau_1), \dots, x^{(k)}(t + \tau_n)\right) dt = E[g(\mathbf{x}(t), \mathbf{x}(t + \tau_1), \dots, \mathbf{x}(t + \tau_n))] \quad (B.4)$$

エルゴート性の厳密な数学的条件は本稿では取り扱えないが、対象となる確率過程がマルコフ過程および定常過程であることが必要条件である。

マルコフ性については、本章ではFastADRの継続時間は5分間と仮定しており、それに対して実際のFastADR発令間隔が十分長くマルコフ性が近似可能であろう。定常過程については、本章の研究対象である5分間平均電力量であれば空調負荷や外気温など時定数が長い変化の影響は少ないのでその間は定常確率過程と仮定できると思われる。

エルゴート性を仮定するにはビルマルチ空調設備の均一性が問題であろう。今回の実験ではビル1棟が5ブロックで、各ブロックは同一メーカの標準機種であり定格冷房能力40[kW]～73[kW]の5型式で構成されている。しかし、量産標準品とはいえエルゴート性は証明できていない。これまでビル1棟分5台のマルチ空調設備の繰返し標本和が正規分布に近づくことを検討した。次に数百種類のビルマルチFastADRアグリゲーションモデルを構築して同時重ね合せシミュレーションを実行させてエルゴート性を検証する必要がある。

付録C FastADR 応答の重ね合せ時系列の探索

C. 1 重ね合せ時系列の探索プログラム

第6章では、時刻の異なる数台のビルマルチ空調データを混在させて組合せ合成した重ね合せ時系列データを用いて、FastADR 重ね合せアグリゲーションを検討した。その組み合わせ合成に際し、条件を満たす組み合わせの探索には遺伝的アルゴリズムを用いた。本付録では、この探索処理をおこなう R 言語プログラムの主要なソースコードを示す。

GA3.R

```
# GA: 遺伝的アルゴリズム

library(GA)
library(purrr)

#' 選択されたデータセットのみを取り出す
#'
#' @param datasetList 選択元データセット
#' @param x 各データセットの選択(=TRUE)/非選択(=FALSE)を示すベクトル
#'
#' @return 選択されたデータセット
#' @export
#'

selectDataset <- function(datasetList, x){
  return(datasetList[x==1])
}

#
#' 合算PLA の値を取得する
#'
#' @param datasetList 対象データセット
#' @param x 対象データセットの選択(=TRUE)/非選択(=FALSE)を示すベクトル
#'
#' @return 選択されたデータセットの合算PLA 値
#' @export
#'

getAggregatedPl <- function(datasetList, x){
  hit_dslist <- selectDataset(datasetList, x)
  hit_vals <- map_dbl(hit_dslist, ~ .[.$index==1, "pl"])
  return(sum(hit_vals))
}

#
#' GA によるPLA, N を条件とした組み合わせ検索検索
#'
#' @param datasetList 検索元データセット
#' @param target 目標値(PLA)
#' @param targetSize データセット件数
#'
#' @return GA の実行結果
```

```

#' @export
#'
doFitness <- function(datasetList, target, targetSize, target.margin = c(target, target
)) {
  # 個体群の生成
  populationFun <- function (object, ...) {
    population <- matrix(
      as.double(NA), nrow = object@popSize, ncol = object@nBits
    )
    idxSet <- 1:object@nBits
    for(i in 1:object@popSize){
      population[i, ] <- (idxSet %in% sample(idxSet, targetSize)) * 1.0
    }
    return(population)
  }

  # 交差法
  crossoverFun <- function (object, parents, ...) {
    fitness <- object@fitness[parents]
    parents <- object@population[parents, , drop = FALSE]
    n <- ncol(parents)
    children <- matrix(as.double(NA), nrow = 2, ncol = n)
    fitnessChildren <- rep(NA, 2)
    crossOverPoint <- sample(0:n, size = 1)
    if (crossOverPoint == 0) {
      children[1:2, ] <- parents[2:1, ]
      fitnessChildren[1:2] <- fitness[2:1]
    }
    else if (crossOverPoint == n) {
      children <- parents
      fitnessChildren <- fitness
    }
    else {
      cidxSubparents <- (crossOverPoint + 1):n
      #print(paste(crossOverPoint + 1, n, collapse = ","))
      subparentA <- parents[1, cidxSubparents]
      subparentB <- parents[2, cidxSubparents]

      lengthA <- length(subparentA[subparentA == 1])
      lengthB <- length(subparentB[subparentB == 1])

      if(lengthA != lengthB){
        idxA <- (1:length(subparentA))[subparentA == 1]
        idxB <- (1:length(subparentB))[subparentB == 1]

        if(lengthA > lengthB){
          subparentB <- rep(0, length(subparentB))
          subparentB[sample(idxA, lengthB)] <- 1

          subparentA <- rep(0, length(subparentA))
          if(length(setdiff(idxA, idxB)) == 1){
            chooseIdxA <- union(idxA, idxB)
          } else {
            chooseIdxA <- union(idxB, sample(setdiff(idxA, idxB), lengthA - lengthB))
          }
        }
      }
    }
  }
}

```

```

    }
    subparentA[chooseIdxA] <- 1

} else if(lengthA < lengthB) {
    subparentA <- rep(0, Length(subparentA))
    subparentA[sample(idxB, lengthA)] <- 1

    subparentB <- rep(0, Length(subparentB))
    if(length(setdiff(idxB, idxA)) == 1){
        chooseIdxB <- union(idxA, idxB)
    } else {
        chooseIdxB <- union(idxA, sample(setdiff(idxB, idxA), lengthB - lengthA))
    }
    subparentB[chooseIdxB] <- 1
}
}

children[1, ] <- c(parents[1, 1:crossoverPoint], subparentA)
children[2, ] <- c(parents[2, 1:crossoverPoint], subparentB)

if(Length((children[1, ])[children[1, ]==1]) != targetSize){
    browser()
}
if(Length((children[2, ])[children[2, ]==1]) != targetSize){
    browser()
}
}
out <- list(children = children, fitness = fitnessChildren)
return(out)
}

# 突然変異
mutationFun <- function (object, parent, ...) {
    mutate <- parent <- as.vector(object@population[parent, ])
    oneIdxSet <- (1:Length(parent))[parent == 1]
    zeroIdxSet <- (1:Length(parent))[parent != 1]
    onej <- sample(oneIdxSet, size = 1)
    zeroj <- sample(zeroIdxSet, size = 1)
    mutate[onej] <- 0
    mutate[zeroj] <- 1
    return(mutate)
}

# フィットネス関数 (最大化する)
fitnessFun <- function(x) {
    hit_dslist <- datasetList[x == 1]
    hit_vals <- map_dbl(hit_dslist, ~ .[.$index==1, "PL"])
    sum_val <- sum(hit_vals)
    if(sum_val >= target.margin[1] && sum_val <= target.margin[2]){
        return(0.0)
    }
    err <- abs(target - sum_val)
    ret <- -err
    return(ret)
}

```

```

}

GA <- ga(
  type = "binary",
  fitness = fitnessFun,
  nBits = length(datasetList),
  maxiter = 1000,
  run = 100,
  #pcrossover = 0.9,
  #pmutation = 0.2,
  popSize = 50,
  population = populationFun,
  mutation = mutationFun,
  crossover = crossoverFun
  #monitor = function(...){}
)
summary(GA)
plot(GA)

return(GA)
}

```

20170915_Average_Effect_6.R

```

source("average_effect_per_n.R")
source("common.R")
source("GA3.R")
library(scales)
library(stringr)
library(tidyr)

# Function -----
createResult <- function(x){
  xNum <- length(x)
  xMean <- mean(x)
  xVar <- 1/xNum * sum((x - xMean)^2)
  xSd <- sqrt(xVar)
  return(list(num=xNum, mean=xMean, var=xVar, sd=xSd))
}

# Main -----
# データセット読み込み
if(!exists("bacds_list")){
  bacds_list <- load.all_datasets()
  bacds_idx <- 1:length(bacds_list)
}

# 合計がN=10, ..., PL=5, ...kWとなるデータセットを検索
n_list <- c(1, 10, 20, 50, 100)
target <- 5
offset <- 0.1
max_times <- 20

```

```

if(!exists("all_pair_list")){
  all_pair_list <- list()

  for(n in n_list){
    t_pla <- target * n
    t_pla.margin <- c((target-offset), (target+offset)) * n
    print(paste0("n=", n, ", pla=", t_pla, "kW, margin=", paste0(t_pla.margin, collapse = " ~ ")))
    info <- paste0("n=", n, ", pla=", t_pla, " kW")

    if(n==1){
      candidates_idx <- bacds_idx[map_lgl(bacds_list, function(ds){
        abs(ds$index == 0, "PL"] - t_pla) <= offset
      })]

      candidate_pairs_list <- lapply(candidates_idx, function(c){
        x <- rep(FALSE, length(bacds_list))
        x[c] <- TRUE
        return(x)
      })

      num <- ifelse(Length(candidate_pairs_list) < max_times, Length(candidate_pairs_list),
      max_times)
      pair_list <- sample(candidate_pairs_list, num)

    } else {
      pair_list <- list()
      sub_bacds_idx <- bacds_idx
      sub_bacds_list <- bacds_list
      cnt <- rep(0, Length(bacds_list))

      is_reset <- FALSE

      while(TRUE){
        # GA による探索処理
        info <- paste0("n=", n, ", pla=", t_pla, " kW, i=", length(pair_list))
        print(info)
        ga <- try(
          doFitness(sub_bacds_list, t_pla, n, target.margin = t_pla.margin),
          silent = FALSE
        )

        # 見つからない場合は中止
        if(class(ga) == "try-error" || abs(ga@fitnessValue) > offset){
          break
        }

        # ペアを生成
        candidate_pairs_list <- unlist(lapply(ga@solution, 1, function(row) {
          list(bacds_idx %in% sub_bacds_idx[row==1])
        }), recursive = F)

        # 既に存在するペアを削除する
      }
    }
  }
}

```

```

candidate_pairs_list <- setdiff(candidate_pairs_list, pair_list)

# 既に存在するペアしかない場合はリセット
if(Length(candidate_pairs_list) <= 0){
  next
}

# 1つのみを抽出する
j = sample(1:Length(candidate_pairs_list), 1)
pair_list <- c(pair_list, candidate_pairs_list[j])

cnt <- cnt + as.numeric(candidate_pairs_list[[j]])

# 選択されたデータを排除
sub_bacds_idx <- bacds_idx[cnt<=3]
sub_bacds_list <- bacds_list[cnt<=3]

# 残りデータ数が少ない場合もリセットする
if(Length(sub_bacds_list) < n){
  break
}

# 件数が以上となったら終了
if(length(pair_list) >= max_times){
  break
}
}

all_pair_list[[info]] <- pair_list
}

}

# 検索結果より、合算結果を生成する
if(!exists("all_aggds_List")){
  all_aggds_list <- list()
  for(pair_list_name in names(all_pair_list)) {
    pair_list <- all_pair_list[[pair_list_name]]
    ds_list <- map(pair_list, ~ selectDataset(bacds_list, .))
    aggds_list <- list()
    for(ds in ds_list){
      aggds <- aggregate_bac_dframes_by_sum(ds)
      aggds_list <- c(aggds_list, list(aggds))
    }
    all_aggds_list[[pair_list_name]] <- aggds_list
  }
}

# 各ステップの特徴データ
bac_data_info <- data_frame(id=bacds_idx)
bac_data_info["P_LB"] <- map_dbl(bacds_list, function(ds){ ds[ds$index == -1, "PL"] })
bac_data_info["P_LA"] <- map_dbl(bacds_list, function(ds){ ds[ds$index == 0, "PL"] })
bac_data_info["u_P_B"] <- map_dbl(bacds_list, function(ds){ mean(ds[ds$index < 0, "P"]) })
}

```

```

bac_data_info[ "u_P_A" ] <- map_dbL(bacds_list, function(ds){ mean(ds[ds$index >= 0, "P"]) })
bac_data_info[ "diff_A" ] <- map_dbL(bacds_list, function(ds){
  sum_p <- sum(ds[ds$index>=0, "P"])
  sum_pl <- sum(ds[ds$index>=0, "PL"])
  diff <- (sum_p - sum_pl)
  return(diff)
})
bac_data_info[ "E_PLA" ] <- map_dbL(bacds_list, function(ds){
  sum_p <- sum(ds[ds$index>=0, "P"])
  sum_pl <- sum(ds[ds$index>=0, "PL"])
  erp <- ((sum_p - sum_pl)/sum_pl) * 100.0
  return(erp)
})

# 各Nにおけるデータ選択個数を出力
for(pair_list_name in names(all_pair_list)) {
  n <- as.numeric(str_match(pair_list_name, "n=(\\d\\d\\d\\d)"))[[2]]
  pair_list <- all_pair_list[[pair_list_name]]
  cnt <- rep(0, length(bacds_list))
  for(pair in pair_list){
    cnt <- cnt + as.numeric(pair)
  }
  bac_data_info[paste0("cnt(n=", n, ")")] <- cnt
}

write.csv(bac_data_info, file = "bac_data_info.csv")

```

付録D 仮想ビルの多様性モデリング定義

本付録では、第5章にておこなった仮想ビルの多様性モデリングについて、その定義詳細を示す。

D.1 BEM1.1型（中型オフィスビル型）のビルクラス定義

5.3.1項の表5.1の詳細を次表に示す。

Building No.	Building type	BEM type	フロア	位置	OU	AE type	Room type	設置箇所
1	Medium-sized office building	BEM1.1	1F	E	1	Type1	shop	売店
				W	2	Type1	lobby	ロビー
			2F	W	3	Type3	storage1	倉庫
				E	4	Type3	storage2	倉庫
			3F	W	5	Type1	office1	事務室
				E	6	Type1	office2	事務室
			4F	W	7	Type2	server1	サーバ室
				E	8	Type2	server2	サーバ室
			5F	W	9	Type3	confroom1	会議室
				E	10	Type3	confroom2	会議室
			6F	W	11	Type1	office3	事務室
				E	12	Type1	office3	事務室
			7F	W	13	Type1	office4	事務室
				E	14	Type1	office4	事務室
			8F	W	15	Type2	server3	CAD室
				E	16	Type2	server3	CAD室
			9F	W	17	Type3	confroom3	大会議室
				E	18	Type3	confroom4	役員フロア
			10F	W	19	Type2	lunchroom1	食堂
				E	20	Type2	lunchroom1	食堂

D.2 FastADR 離脱条件 定義

5.3.2 項の表 5.2 の詳細を次表に示す。

OU No.b	パラメータ	時間帯番号 <i>h</i>											
		7	8	9	10	11	12	13	14	15	16	17	18
1	室内機運転	6	6	6	6	6	6	6	6	6	6	0	0
	設定温度	29.0	26.0	26.0	26.0	24.0	24.0	25.0	25.0	25.0	25.0	26.0	26.0
	熱負荷倍率	0.3	1.0	1.0	1.0	1.5	2.0	1.5	1.5	1.5	1.5	1.0	1.0
	OptOut	5.0	2.0	2.0	2.0	0.5	0.5	2.0	2.0	2.0	2.0	2.0	2.0
2	室内機運転	0	6	6	6	6	6	6	6	6	6	0	0
	設定温度	29.0	28.0	28.0	28.0	28.0	28.0	28.0	28.0	28.0	28.0	29.0	29.0
	熱負荷倍率	0.5	1.0	1.0	1.5	1.5	1.5	2.0	1.5	1.5	1.5	1.0	1.0
	OptOut	5.0	3.0	3.0	3.0	3.0	3.0	3.0	3.0	3.0	3.0	5.0	5.0
3	室内機運転	6	6	6	6	6	6	6	6	6	6	6	6
	設定温度	29.0	29.0	29.0	29.0	29.0	29.0	29.0	29.0	29.0	29.0	29.0	29.0
	熱負荷倍率	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
	OptOut	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0
4	室内機運転	6	6	6	6	6	6	6	6	6	6	6	6
	設定温度	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0
	熱負荷倍率	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
	OptOut	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0	5.0
5	室内機運転	0	6	6	6	6	0	0	0	6	6	0	0
	設定温度	29.0	25.0	25.0	25.0	25.0	29.0	25.0	25.0	25.0	25.0	29.0	29.0
	熱負荷倍率	0.3	0.7	1.0	1.3	1.5	0.3	0.3	0.3	0.5	1.0	0.3	0.3
	OptOut	5.0	1.0	1.0	1.0	1.0	5.0	1.0	1.0	1.0	1.0	5.0	5.0
6	室内機運転	0	6	6	6	6	0	6	6	6	6	6	6
	設定温度	25.0	25.0	25.0	25.0	25.0	29.0	25.0	25.0	25.0	25.0	25.0	25.0
	熱負荷倍率	0.3	0.5	1.0	1.0	1.0	0.5	1.3	1.3	1.5	1.5	1.5	1.5
	OptOut	1.0	1.0	1.0	1.0	1.0	5.0	1.0	1.0	1.0	1.0	1.0	1.0

OU No.b	パラメータ	時間帯番号 <i>h</i>											
		7	8	9	10	11	12	13	14	15	16	17	18
7	室内機運転	6	6	6	6	6	0	6	6	6	6	6	6
	設定温度	22.0	22.0	22.0	22.0	22.0	22.0	22.0	22.0	22.0	22.0	22.0	22.0
	熱負荷倍率	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
	OptOut	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5
8	室内機運転	6	6	6	6	6	0	6	6	6	6	6	6
	設定温度	23.0	23.0	23.0	23.0	23.0	23.0	23.0	23.0	23.0	23.0	23.0	23.0
	熱負荷倍率	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
	OptOut	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
9	室内機運転	0	0	0	6	6	0	6	6	6	6	0	0
	設定温度	29.0	29.0	29.0	25.0	25.0	29.0	25.0	25.0	25.0	25.0	29.0	29.0
	熱負荷倍率	0.3	0.3	0.3	1.0	1.0	0.3	1.3	1.3	2.0	2.0	0.7	0.7
	OptOut	5.0	5.0	5.0	1.0	1.0	5.0	1.0	1.0	1.0	1.0	5.0	5.0
10	室内機運転	0	0	6	6	0	0	0	0	6	6	6	6
	設定温度	29.0	29.0	25.0	25.0	29.0	29.0	29.0	29.0	25.0	25.0	25.0	25.0
	熱負荷倍率	0.3	0.3	1.0	1.3	0.3	0.3	0.3	0.3	1.5	1.5	1.5	1.5
	OptOut	5.0	5.0	2.0	2.0	2.0	5.0	5.0	5.0	2.0	2.0	2.0	2.0
11	室内機運転	0	6	6	6	6	0	6	6	6	6	0	0
	設定温度	29.0	25.0	25.0	25.0	25.0	29.0	25.0	25.0	25.0	25.0	29.0	29.0
	熱負荷倍率	0.3	1.0	1.0	1.0	1.0	0.3	0.7	0.5	0.5	0.7	1.0	1.0
	OptOut	5.0	1.0	1.0	1.0	1.0	5.0	3.0	3.0	3.0	1.0	1.0	1.0
12	室内機運転	0	6	6	6	6	0	6	6	6	6	0	0
	設定温度	29.0	25.0	25.0	25.0	25.0	29.0	25.0	25.0	25.0	25.0	29.0	29.0
	熱負荷倍率	0.3	1.0	1.0	1.0	1.0	0.3	0.7	0.5	0.5	0.7	1.0	1.0
	OptOut	5.0	1.0	1.0	1.0	1.0	5.0	3.0	3.0	3.0	1.0	1.0	1.0
13	室内機運転	6	6	6	6	6	0	6	6	6	6	6	6
	設定温度	26.0	26.0	26.0	26.0	26.0	29.0	26.0	26.0	26.0	26.0	26.0	26.0
	熱負荷倍率	0.5	1.0	1.0	1.0	1.0	0.5	1.5	1.5	1.5	1.5	0.5	0.5
	OptOut	5.0	2.0	2.0	2.0	2.0	5.0	1.0	1.0	1.0	1.0	3.0	3.0

OU No.b	パラメータ	時間帯番号 <i>h</i>											
		7	8	9	10	11	12	13	14	15	16	17	18
14	室内機運転	6	6	6	6	6	0	6	6	6	6	6	6
	設定温度	26.0	26.0	26.0	26.0	26.0	29.0	26.0	26.0	26.0	26.0	26.0	26.0
	熱負荷倍率	0.5	1.0	1.0	1.0	1.0	0.5	1.5	1.5	1.5	1.5	0.5	0.5
	OptOut	5.0	2.0	2.0	2.0	2.0	5.0	1.0	1.0	1.0	1.0	3.0	3.0
15	室内機運転	0	6	6	6	6	6	6	6	6	6	6	6
	設定温度	29.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0
	熱負荷倍率	0.3	0.7	1.0	1.0	1.0	0.3	1.3	1.3	1.3	1.0	1.0	1.0
	OptOut	3.0	1.0	1.0	1.0	1.0	2.0	0.5	0.5	0.5	1.0	1.0	1.0
16	室内機運転	0	6	6	6	6	6	6	6	6	6	6	6
	設定温度	29.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0
	熱負荷倍率	0.3	0.7	1.0	1.0	1.0	0.3	1.3	1.3	1.3	1.0	1.0	1.0
	OptOut	3.0	1.0	1.0	1.0	1.0	2.0	0.5	0.5	0.5	1.0	1.0	1.0
17	室内機運転	0	0	0	6	6	6	0	0	0	0	0	0
	設定温度	29.0	29.0	29.0	26.0	26.0	26.0	29.0	29.0	29.0	29.0	29.0	29.0
	熱負荷倍率	0.3	0.3	0.3	1.0	1.0	1.0	0.3	0.3	0.3	0.3	0.3	0.3
	OptOut	5.0	5.0	5.0	0.5	0.5	0.5	5.0	5.0	5.0	5.0	5.0	5.0
18	室内機運転	6	6	6	6	6	6	6	6	6	6	6	6
	設定温度	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0	25.0
	熱負荷倍率	1.0	1.0	1.0	1.0	1.0	1.0	0.3	0.3	1.0	1.0	0.3	0.3
	OptOut	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.2
19	室内機運転	0	0	6	6	6	6	6	6	6	6	6	6
	設定温度	29.0	29.0	28.0	28.0	25.0	25.0	25.0	26.0	26.0	26.0	28.0	28.0
	熱負荷倍率	0.3	0.3	1.0	1.0	2.0	3.0	2.0	0.7	0.7	0.3	1.5	1.5
	OptOut	5.0	5.0	3.0	3.0	0.2	0.2	0.5	3.0	3.0	5.0	2.0	2.0
20	室内機運転	0	0	6	6	6	6	6	6	6	6	6	6
	設定温度	29.0	29.0	28.0	28.0	25.0	25.0	25.0	26.0	26.0	26.0	28.0	28.0
	熱負荷倍率	0.3	0.3	1.0	1.0	2.0	3.0	2.0	0.7	0.7	0.3	1.5	1.5
	OptOut	5.0	5.0	3.0	3.0	0.2	0.2	0.5	3.0	3.0	5.0	2.0	2.0

付録E 設備電力需要応答システム全体の通信

E. 1 緒言

ビル設備を用いた自動需要応答（ADR : Automated Demand Response）として、2.6節の設備電力需要制御システムを考える。このとき、各空調設備はビル毎に地域に分散されて設置されており、ADRを提供するプロバイダはその数百から数千のビル空調設備の電力削減量を合算（アグリゲーション）する必要があり、このアグリゲーションを行う必要があるプロバイダであるアグリゲータに着目する。（図E.1参照）。

このアグリゲータは、一般的にインターネットを使ったクラウドコンピューティングによって行われるだろうと思われる。このため、この通信および処理時間による遅れは、広域で行われる高速なADR（FastADR）において重要な問題となりうる。

将来のFastADRにおいてアグリゲータは、出来る限り高速に（例えば1分以内に）広域に散らばって存在する数百棟のビルから電力消費量をアグリゲーションすることを期待されている[47]-[49]。しかしながら、既存のビル設備では高速な動作が出来るような設計になっていない。加えて、セキュリティ上の理由からアグリゲータから直接ビル側に接続できないような設定になっていることが多く、この場合定期的にビル設備側からアグリゲータに接続する必要がある。

したがって、2.9節で述べたように本論では制御対象設備の応答時間のみを対象としていたが、アグリゲーションによる遅れはそれ以外の要素も含めると想像以上に大きくなる場合があり、そして確率的に分散するだろうと考えられる。けれども、このADRアグリゲーション時の遅れの問題についての定量的な研究はなされていないように思える。

そこで本付録では、あるビルの空調設備で測定された電力消費量の時系列データより抜き出したいくつの全停止パターンを基にして、空調設備の電力削減における遅れのモデルを合成した。そして実際のインターネット環境上で、そのモデルを使用した100台のビル空調設備の電力削減エミュレータを用いて、リアルタイムでのADRアグリゲーションの通信実験を行った。

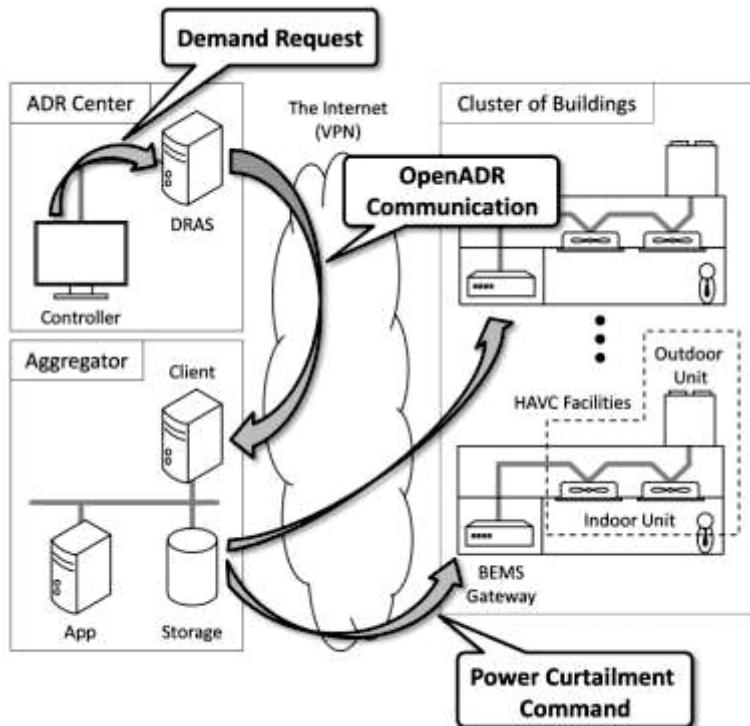


図 E.1 ADR アグリゲーションシステムの概念図

E.2 ADR クラウドアグリゲーション

E.2.1 OpenADR システム設計

OpenADR[50]アグリゲーションのためのクラウドコンピューティングシステムの概念図が図E.1である。本システムはOpenADRにおけるDemand Response Automation Server (DRAS) 及びADRアグリゲータ、数多くのビルエネルギー管理システム(BEMS) ゲートウェイで構成される。そしてADRアグリゲータは、DRASに対するクライアントアプリケーションとアグリゲーションアプリケーション、ストレージサーバを持つ。一般にセキュリティを理由にして、アグリゲータから各ビルのBEMS ゲートウェイにTCP/IPコネクションを張ることは出来ないことが多い。そこでアグリゲータは電力削減指令をストレージサーバに設定しておき、各ゲートウェイの接続を待つ。各ゲートウェイは定期的にストレージサーバに接続し指令の取得、及び電力消費量の報告を行う。セキュリティを考えた場合、このような手順がアグリゲータとゲートウェイ間の通信では必要となる。

E.2.2 IEEE1888 の利用

ADRアグリゲータはセキュリティや運用コストなどといった理由により、遠隔地に設置されることもありうる。また、アグリゲータのサーバマシンやワークステーションも同様の理由で互いに離れた場所に設置することもあるだろう。この場合、インターネット回線上のVPNを用いたWebサービスでの通信をする必要があると思われる。

本章では、アグリゲータ・BEMS ゲートウェイ間のWebサービスのプロトコルとしてIEEE1888 [51]-[55]を想定している。このプロトコルは、機器の操作・記録を目的とした時系列データの転送が可能であり、スマートグリッドのために特に開発されているプロトコルである。本章では、広域域かつ大規模、それでいて遅れに敏感でなければならぬクラウドコンピューティングでのADRアグリゲーションを想定している。

このような場合、プロトコルが一貫したタイムスタンプの付いたデータを扱えることが非常に重要となる。加えてプロトコルはタイムスタンプを持つデータをストレージで読み書きできる機能を持つべきである。IEEE1888はこの要求を満たすプロトコルである。

E.3 ビルマルチ空調設備

E.3.1 ビルマルチ空調設備における電力量計

典型的な中規模オフィスビルでは、毎月/毎日の電気料金の請求のための電力量計が設置されていることが多い[56][57]。電力量計はある一定量の電力量毎にパルスを発する。BEMS ゲートウェイはこのパルスの数を数えることで電力量を把握する。このような従来からある電力量計測システムに用いられる電力量計の分解能は非常に粗いものが多い。もちろん現在では、より洗練された高分解能の電力量計が既に数多く存在する。しかし現時点においては、より市場に出回っている従来の電力量計について想定しなければならない。

E.3.2 ビルマルチ空調設備における制御構造

ビルマルチ空調設備では、すべての室内機と室外機ユニットはフィールドバスと呼ばれる通信ネットワーク線に接続される。このフィールドバスによる通信の流れの例を図 E.2 に示している。この例では、BEMS ゲートウェイがアグリゲータから全停止の電力削減指令を受け取った場合の流れを説明している。まず BEMS ゲートウェイは All-Off 処理を開始し、IndoorUnitOff コマンドを各室内機ユニットに送る。このとき IndoorUnitOff コマンドは、常時の通信と同様に各室内機ユニットに順々に送られる。各室内機ユニッ

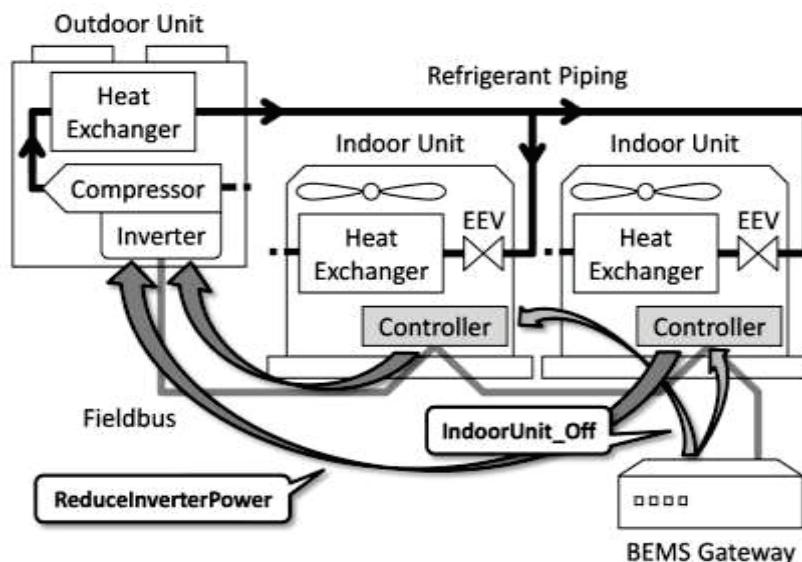


図 E.2 VRF 型ビル空調設備における冷房

トはそのEEVを閉じて熱交換を停止し、ReduceInverterPowerコマンドを室外機に送信する。その室外機が担う全ての室内機からReduceInverterPowerコマンドを受信すると、室外機のインバータは電源を落とす。なおBEMSゲートウェイは通信によってAll-Off処理が完了したか把握する。

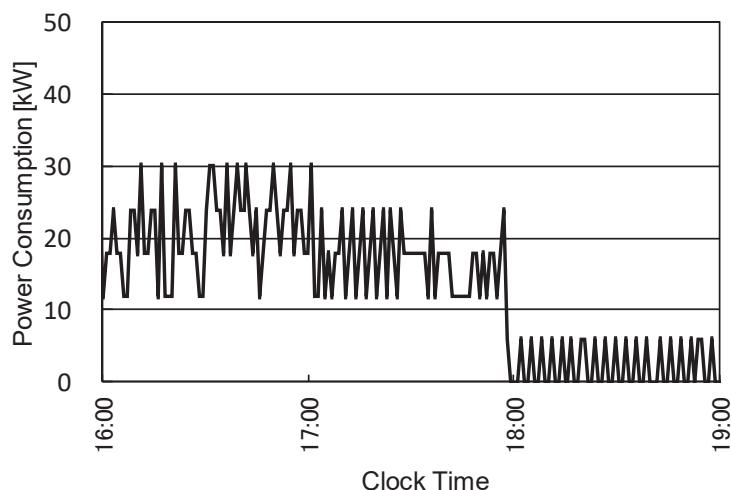
上述のようにインバータが停止するまでには何百もの通信と制御手順が必要となり、このような手順を経て空調が停止、電力削減となる。

一般に、典型的なビルマルチ空調設備システムではAll-Off処理が完了するまでに1分以上かかる場合も多く、これはADRの電力削減遅延の一つの要素となる。

E.4 電力削減モデル

E.4.1 実際のビル電力時系列データの計測

電力削減における現実の過渡応答を得るために、制御した場合に相当する時系列データを実際のあるオフィスビルで計測した。表E.1はそのオフィスビルの概略である。このビルは典型的な中規模オフィスビルで、ポピュラーなビルマルチ空調システムが設置されている。この空調設備の時系列データは、フィールドバスを通じてBEMSゲートウェイに集められ、1分刻みでログとして保存されたものである。図E.3は電力消費量の時系列データの一例である。なお1分刻みというのは、従来的なビル空調管理・制御システムにおいて実用上十分な時間粒度である。



図E.3 空調設備の電力消費データの例

表 E.1 計測対象のオフィスビルの概要

Item	Specification
Type	General office
Total floor area	About 2500m ²
Number of floors	2
Structure	Steel frame
Number of HVAC indoor units	30
Watt-hour meter of resolution	0.1 Wh/pulse

ビル空調設備の指令データの処理時間は、すなわち BEMS ゲートウェイ、室内機ユニット、室外機ユニットらにおける各処理時間およびフィールドバスの通信遅延は数秒以内である。

Pull (クライアントからサーバに接続) することにより最新のアグリゲータの電力削減指令を得るために、各 BEMS ゲートウェイから TCP コネクションを開始して IEEE1888 FETCH リクエストを定期的に送信しなければならない(command pull)。また BEMS ゲートウェイは電力値報告の IEEE1888 WRITE リクエストもまた送信する (curtailment report)。この command pull/curtailment report の送信間隔は 1 分固定であり、これは従来のビル設備システムで現実的で典型的な間隔である。

E.4.2 電力削減遅延モデルの作成

本章では、ビルの棟数は電力消費を合算したときに約 5MW となるように決定した。この 5MW という値は、いわゆるメガソーラー発電所の出力に近い値である。私たちはフィールドテストにより空調全停止の時系列データのサンプルを 25 個得た。そこで各サンプルに 4 つのスケールを掛けることで、100 個のパターンを作成した。

そして図 E.4 に示すように、その 100 個のビル空調全停止パターンを合成し、100 棟分のビル電力削減遅延モデルとした。この図では、100 個のリアルタイム全停止パターンを、各パターンにおいて電力削減指令がアグリゲータのストレージサーバに登録された時刻を基準に重ねている。

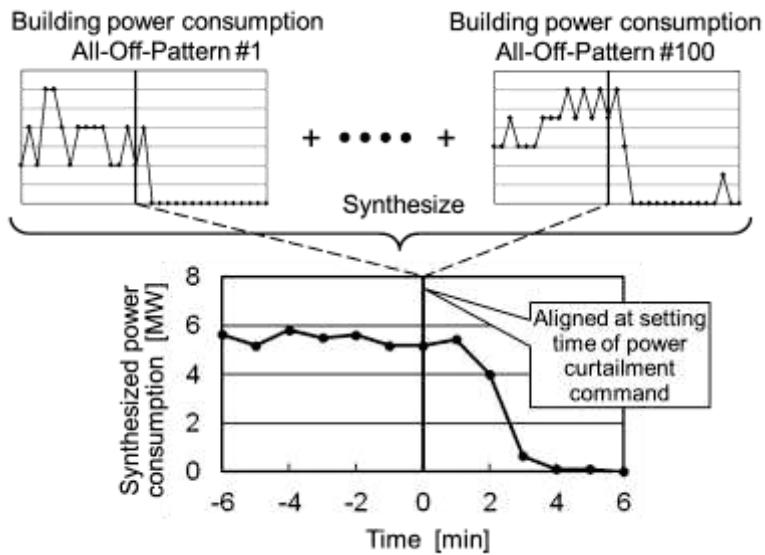


図 E.4 電力削減遅延モデルの作成

E.5 アグリゲーション通信試験

E.5.1 ADR アグリゲーション通信の実装

本章における試験システムの実装は次の通りである。米国カリフォルニアの ADR センターにある実際の DRAS を使用した。岐阜大学の研究室から DRAS へのインターネット接続には WiMAX を利用している。

先にも述べたがアグリゲータの構成要素には DRAS に対するクライアントアプリケーション(DRAS クライアント)とアグリゲーションアプリケーション、ストレージサーバがある。そしてストレージサーバは DRAS からの ADR イベントを蓄える ADR イベントストレージ、電力削減指令を設定する指令ストレージの 2つがある。

ビル空調エミュレータは、1台の PC 上で空調電力削減遅延モデルを用いて仮想 BEMS ゲートウェイ 100 個をエミュレーションしたものである。アグリゲータを構成する全コンポーネント及びビル空調エミュレータが起動している PC は岐阜大学の研究室内の LAN に接続されている。

なお本章において「エミュレーション」という言葉は、リアルタイムに振る舞うという意味で使用している。

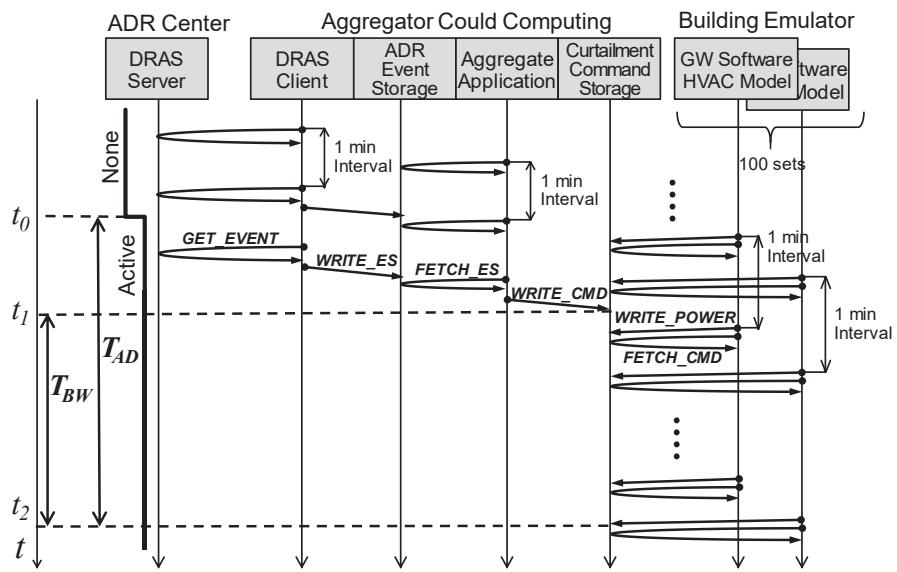


図 E.5 試験システムのシーケンス図

図 E.5 は試験システムの通信シーケンス図である。本実装では全ての通信をクライアント・サーバー型で設計している。これは典型的なインターネットに対するファイアウォールのセキュリティポリシーによるものであり、すなわちこの設計ではクライアント側からサーバ側に対して TCP コネクションを張らなければならない。

したがって、DRAS クライアントは定期的に DRAS に対し TCP コネクションを張り、1 分周期で OpenADR GET_EVENT Web サービスを使い ADR イベントを取得し、ADR イベントストレージにそれを書き込む。同様にアグリゲーションアプリケーションも 1 分周期で ADR イベントを取得、それより各ビルに出す指令を決定して指令ストレージに書き込む。さらに各仮想 BEMS ゲートウェイは独立した 1 分周期で、指令ストレージに TCP コネクションを張り、まず IEEE1888 WRITE_POWER Web サービスにより現在の電力値報告を行う。そのすぐ後にその BEMS ゲートウェイは IEEE1888 FETCH_CMD Web サービスにより指令を取得する。各 BEMS ゲートウェイは当然それぞれ異なるビルに位置していると考えられるので、WRITE_POWER と FETCH_CMD の 1 分周期の実施は互いに非同期となる。

E.5.2 ADR アグリゲーション通信試験の結果

ADR アグリゲーション通信試験では、緊急時を想定して事前のアグリゲータ側への DR スケジュールの通知は無いものとし、ADR イベントとして全停止の電力削減指令を

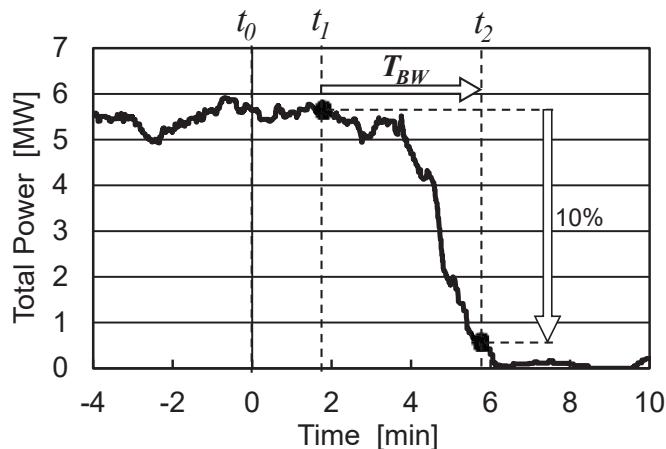


図 E.6 試験結果の例

設定し試験を行った。図 E.6 は 100 棟のビル空調エミュレータがアグリゲータに報告した電力値を合算した合計電力の ADR アグリゲーションの過程の一例である。前節で述べたように、エミュレータの各仮想 BEMS ゲートウェイは独立して 1 分周期で現在の電力値を報告する。そのため合計電力の描くカーブには連続的な変化が現れる。また空調設備の合計電力は 0 にはならない。すなわち、たとえインバータがその動作を停止していたとしても、いくつかの機器は電力を消費している。したがって本章においては、アグリゲータの指令ストレージに全停止の電力削減指令が設定された時 t_1 の合計電力に対して、10%以下に合計電力がなったときを電力削減の完了した時刻 t_2 と定義した。また時刻 t_1 から t_2 の間の時間をアグリゲーション遅延 T_{BW} 、DRAS の ADR イベントが設定している開始時刻を t_0 、そして時刻 t_0 から t_2 間の時間を全 ADR アグリゲーション遅延 T_{AD} と定義した。

ADR アグリゲーション通信試験を 83 回行った結果、 T_{BW} の平均は 259 秒(4.3 分)となった。また T_{AD} の平均は 346 秒(5.8 分)である。つまりアグリゲーション遅延 T_{BW} が全 ADR アグリゲーション遅延 T_{AD} の約 70% を占めることとなる。

E.6 考察

アプリケーションの機能的な観点からは、アグリゲータが各ビルの BEMS ゲートウェイに電力削減指令の情報を流す。しかし従来のネットワーク接続の体系では、アグリゲータからの指令情報取得に各ビルが Pull する方が普通である。これは一般的なビルのセキュリティポリシーでは、アグリゲータに各 BEMS ゲートウェイからトランスポート層の接続を始めなければならないからである。このことは DRAS・アグリゲータ間の接続にも当てはまり、DRAS に対して ADR イベント取得のために（アグリゲータの）DRAS クライアントは Pull する。

常に最新の結果を得るために定期的に Pull する必要があり、その間隔は短いほどよい。そうであるにもかかわらず、従来的なビル管理システムで現実的な Pull 間隔は 1 分であるだろう。その主な理由は従来の電力量計のパルス数による電力量の測定手法である。この手法では一定の電力量毎にパルスに変換されるため、少なからずパルス間隔は空く。全 ADR アグリゲーション遅延のように、BEMS ゲートウェイが All-Off 処理を開始しインバータを停止させ、同時に従来的な電力量計で電力を測定すると約数分かかる。アグリゲータの視点からみるとビル 1 棟の電力に比べ、100 棟のビルの合計電力の（従来の電力計に起因して確率的に発生する）微小な変動は減るように思える。その理由は、通信タイミングが図 E.6 のように非同期であるからだと考えられる。

ここで全 ADR アグリゲーション遅延 T_{AD} の平均「6 分」では、第 3 章で制御フレームの長さとして設定した「5 分」を満たさないように思えるが、想定するサービスが異なるため問題にはならない。前者の全 ADR アグリゲーション遅延 T_{AD} は、電気会社からのデマンドレスポンス通信から空調機全停止完了までの時間を指し、緊急時を想定して発動前にアグリゲータ側への DR スケジュールの通知は無いものを仮定している。後者は、事前に RTP 単価スケジュールの通知があり、それを元に RTP 制御スケジュールプランを用意するものを想定している。ゆえに電力会社とのデマンドレスポンス通信は都度おこなわず、1 度だけかつ事前にスケジュールを各ビルに通知する形となるため、遅延は前者よりも小さい。

E.7 結言

本付録では以下のことが得られた。

- (1) 従来的な電力量計・インターネットに対するファイアーウォールポリシーを想定した試験では、本章で作成した遅延モデルを用いたビル空調設備エミュレータ 100 台（5MW 相当）の電力削減報告のアグリゲーション（合算）に平均 5.8 分かかる。
- (2) 遅延の約 70%はアグリゲータの電力削減指令の設定と、各ビルの BEMS ゲートウェイが定期的に実行する指令取得・結果報告の間の確率的な時間の違いからくる。

参考文献

- [1] 蜂川忠三：「仮想発電所システムの構築技術」，オーム社（2019）
- [2] 第二百三回国会における菅内閣総理大臣所信表明演説（2020）
- [3] 西岡秀三：「脱炭素社会はなぜ必要か、どう創るか」，国立環境研究所 地球環境センターニュース，Vol.31，No.11（2021）
- [4] 西川緯一，手塚哲央，喜多一，姜文盛：「電力負荷との相関を考慮した太陽光発電システムの経済性評価」，電学論B，Vol.111，No.6，pp.587-595（1991）
- [5] 後藤和夫，内川洋司，永田豊，藤井靖彦：「電源構成を考慮した太陽光発電の導入評価分析」，電学論B，Vol.115，No.12，pp.1438-1445（1995）
- [6] S. Shivashanjar, S. Mekhilef, H. Mokhlis and M. Karimi: “Mitigating methods of powerfluctuation of photovoltaic (PV) sources—A review”, Renewable and Sustainable Energy, Vol.59, pp.1170-1184 (2016)
- [7] P. Sorensen et al.: “Power Fluctuations from Large Wind Farms”, IEEE Transactions on Power Systems, Vol.22, No.3, pp.958-965 (2007)
- [8] M. Jabir, H.A. Illias, S. Raza and H. Mokhlis: “Intermittent Smoothing Approaches for Wind Power Output: A Review”, Energies 2017, No.10, pp.1572-1595 (2017)
- [9] California independent system operator: “What the duck curve tells us about managing a green grid” (2016)
- [10] 環境省：「平成27年度低炭素社会の実現に向けた中長期的再生可能エネルギー導入拡大方策検討調査委託業務報告書」（2016）
- [11] 牛尾剛：「再生可能エネルギー大量導入に向けた 課題と取り組み」，オペレーションズ・リサーチ，Vol.58，No.5，pp.254-260（2013）
- [12] 新エネルギー・産業技術総合開発機構：「NEDO 再生可能エネルギー技術白書（第2版）」（2014）
- [13] International Energy Agency: “The Power of Transformation” (2015)
- [14] International Energy Agency: “System Integration of Renewables: An update on Best Practice” (2018)
- [15] 七原俊也, 井上俊雄:「周波数」，電気設備学会誌, Vol.25, No.10, pp.792-795（2005）
- [16] 柳川茂幸，加藤丈佳，呉錯，田畠彰守，横水康伸，岡本達希，鈴置保雄：「日射量の多地点同時観測に基づく太陽光発電の出力変動に対する LFC 容量の評価」，電学論B，Vol.121, No.9, pp.1094-1102（2001）
- [17] 電力中央研究所：「PV 大量導入が大電源脱落時の周波数低下に及ぼす影響」，電力中央研究所報告（2018）

- [18] 電力広域的運営推進機関：「調整力の定義及び調整力確保計画の対象について」，調整力及び需給バランス評価等に関する委員会，第6回 調整力等に関する委員会，資料6（2015）
- [19] 井上俊雄：「電力系統の周波数制御から見た火力機の出力応動特性」，電学論B, Vol.124, No.3, pp.343-346 (2004)
- [20] 島田秀顕：「火力発電の最新動向と付加価値向上への取り組み」，東芝レビュー，Vol.74, No.3, pp.2-9 (2019)
- [21] 経済産業省資源エネルギー省：「今冬の電力需給逼迫に係る検証について」，電力・ガス事業分科会，電力・ガス基本政策小委員会，第30回 総合資源エネルギー調査会，資料6（2021）
- [22] 経済産業省資源エネルギー省：「容量市場の見直しに向けた検討状況」，電力・ガス事業分科会，電力・ガス基本政策小委員会アグリゲーション，第32回 総合資源エネルギー調査会，資料8（2021）
- [23] P. Palensky and D. Dietrich: “Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads”, IEEE Trans. on Industrial Informatics, Vol.7, No.3 (2011)
- [24] V. S. K. Murthy Balijepalli, Vedanta Pradhan, S. A. Khaparde and R. M. Shereef: “Review of Demand Response under Smart Grid Paradigm”, 2011 IEEE PES Innovative Smart Grid Technologies, India (2011)
- [25] 経済産業省資源エネルギー庁：「夏季の電力需給対策について」（2011）
- [26] 小川晨一：「最新の高層ビル対応空調システム」，電気設備学会誌，Vol.38, No.6, pp.299-302 (2018)
- [27] W. Goetzler: “Variable Refrigerant Flow Systems”, ASHRAE Journal 2007, pp.24-31 (2007)
- [28] 空気調和・衛生工学会：「ビル用マルチパッケージ型空調システム—計画・設計から性能評価まで」（2014）
- [29] 日本冷凍空調工業会：「業務用（パッケージ）エアコンの国内出荷台数の推移」
- [30] 送配電網協議会：「需給調整市場の概要・商品要件」（2020）
- [31] 大関崇, 高島工, 大谷謙仁, 菱川善博, 輿水源太郎, 内川恵久, 萩本和彦：「太陽光発電の広域的ならし効果に関する分析・評価」，電気学会論文誌B, Vol.130, No.5, pp.491-500 (2010)
- [32] 経済産業省資源エネルギー省：「エネルギー・リソース・アグリゲーション・ビジネス・ハンドブック」（2018）

- [33] 独立行政法人 新エネルギー・産業技術総合開発機構：「NEDO 再生可能エネルギー技術白書 第2版 一再生可能エネルギー普及拡大にむけて克服すべき課題と処方箋一」(2014)
- [34] K. Ma, G. Hu, C. Spanos: "Distributed Energy Consumption Control via Real-Time Pricing Feedback in Smart Grid", IEEE Trans. on Control System Technology, Vol.22, No.5, pp.1907-1914 (2014)
- [35] 経済産業省・資源エネルギー庁：「次世代エネルギー・社会システム実証事業～総括と今後について～」，第18回次世代エネルギー・社会システム協議会資料，(2019)
- [36] M. Behl, a. Jain, R. Mangharam: "Data-Driven Modeling, Control and Tools for Cyber-Physical Energy Systems", ACM/IEEE 7th Int. Conf. on Cyber-Physical Systems ICCP, pp.1-10 (2016)
- [37] 蟻川 忠三, 青木 佳史, 森川 純次, 稲葉 隆, 近藤 成治, 大嶽 宏之：「リアルタイム電力料金に適応するビルマルチ空調機群の優先エリア複合制御」，空気調和・衛生工学会論文集, Vol.160, No.260, pp.23-30 (2018)
- [38] 蟻川忠三, 青木佳史, 中村惇志, 森川純次, 近藤成治, 稲葉隆：「ビル空調設備スマートグリッド電力抑制予測モデルの平常運転 FastADR 信号モジュレーション訓練法」，電気学会論文誌 B, Vol.138, No.3, pp.199-205 (2018)
- [39] C. Ninagawa, K. Suzuki, A. Nakamura, J. Morikawa: "Applying DNA Analysis Method to Training Data Mining for FastADR Response Model of Air-Conditioning Power Consumption", IEEJ Transactions on Electrical and Electronic Engineering, Vol.12, No.3, pp.440-441 (2017)
- [40] G. Sofronov, T. Polushina, M. Priyadarshana: "Sequential Change-Point Detection via the Cross-Entropy Method", 11th Symposium of Neural Network Application in Electrical Engineering, NEUREL2012, pp.185-188 (2012)
- [41] M. Priyadarshana, G. Sofronov: "Multiple Break-Points Detection in Array CGH Data via Cross-Entropy Method", IEEE Trans. on Computational Biology and Bioinformatics, Vol.1, pp.487-498 (2015)
- [42] N. R. Zhang, D. O. Siegmund: "A modified Bayes information criterion with applications to the analysis of comparative genomic hybridization data", Biometrics, Vol.63, pp.22-32 (2007)

- [43] E. Douglas, et. al.: “Array Comparative Genomic Hybridization Analysis of Colorectal Cancer Cell Lines and Primary Carcinomas”, *The Journal of Cancer Research*, Vol.64, No.14, pp.4817-4825 (2004)
- [44] 中村惇志, 蟻川忠三, 森川純次 :「ビル空調電力 FastADR 制御用ニューラルネットの訓練条件ゾーン分類機械学習」, 電気学会システム研究会, ST-16-047, pp.29-34 (2016)
- [45] S. Kirkpatrick, C. Gelatt, M. Vecchi: “Optimization by Simulated Annealing”, *Science*, Vol.220, No.4598, pp.671-680 (1983)
- [46] C. Ninagawa, S. Kondo, S. Isozumi, and H. Yoshida: “Fine-time-granularity fast demand control of building HVAC facilities for future smart grid”, in Proc. IEEE Int. Conf. on Innovative Smart Grid Technologies, ISGT Europe 2012, pp.1-6 (2012)
- [47] J. Eto, J. Hoffman, and E. Parker: “The Demand Response Spinning Reserve Demonstration - Measuring the Speed and Magnitude of Aggregated Demand Response”, in Proc. 45th Hawaii Int. Conf. on System Sciences, pp.2012-2019 (2012)
- [48] L. Chang-Chien, L. Ngoc, T. Lin, and W. Lee: “Incorporating Demand Response with Spinning Reserve to Realize an Adaptive Frequency Restoration Plan for System Contingencies”, *IEEE Trans.on Smart Grid*, Vol.3, pp.1145-1153 (2012)
- [49] K. Samarakoon, J. Ekanayake, and N. Jenkins: “Investigation of Domestic Load Control to Provide Primary Frequency Response Using Smart Meters”, *IEEE Trans.on Smart Grid*, Vol.3, pp.282-292 (2012)
- [50] California Energy Commission: “Open Automated Demand Response Communications Specification (Ver.1.0)”, CEC-500-2009-063 (2009)
- [51] IEEE standard for Ubiquitous Green Community Control Network Protocol, IEEE Standard 1888-2011, 2011.
- [52] H. Esaki, and H. Ochiai: “The Green University of Tokyo Project”, *IEICE Transaction on Communications*, Vol.J94-B, pp.1225-1231 (2011)
- [53] H. Ochiai, M. Ishiyama, T. Momose, N. Fujiwara, K. Ito, H. Inagaki, A. Nakagawa, and H. Esaki: “FIAP: Facility information access protocol for data-centric building automation systems”, in Proc. IEEE INFOCOM 2011, Workshop on M2MCN-2011, pp.229-234 (2011)
- [54] H. Ochiai: “Power Data Management on the Internet Space: Green ICT Project in Japan”, *IEEE Colombian Communication Conference COLCOM2012*, pp.1-2 (2012)

- [55] C. Ninagawa, H. Yoshida, S. Kondo, and H. Otake: “Data Transmission of IEEE1888 Communication for Wide-area Real-time Smart Grid Applications”, in Proc. International Renewal and Sustainable Energy Conference IRSEC'13, pp.1-6 (2013)
- [56] C. Ninagawa and T. Sato: “BACnet Object Modeling by UML on High-Level Functionality of VRF Air-Conditioning Systems”, American Society of Heating, Refrigerating and Air-Conditioning Engineers ASHRAE Transactions, Vol.115, Part1, pp.338-347 (2009)
- [57] C. Ninagawa, T. Sato and Y. Kawakita: “Virtual Wattmeter Power Consumption Billing Division for Building Air-Conditioners Supporting User's Energy Saving Intention”, Transactions on Electrical and Electronic Engineering, Vol.5, No.6, pp.695-700 (2010)
- [58] S. Chen, H. Gooi, and M. Wang: “Sizing of energy storage for microgrids”, IEEE Trans. on Smart Grid, Vol.3, No.1, pp.142-151 (2012)
- [59] J. L. Mathieu, P. N. Price, S. Kiliccote, and M. A. Piette: “Quantifying changes in building electricity use with application to demand response”, IEEE Trans. on Smart Grid, Vol.2, No.3, pp.507-518 (2011)
- [60] S. Paoletti, M. Casini, A. Giannitrapani, A. Facchini, A. Garulli, and A Vicino: “Load forecasting for active distribution networks”, in Proc. IEEE Innovative Smart Grid Technologies, ISGT Europe 2011 (2011)
- [61] P. Nyeng and J. Ostergaard: “Information and communications systems for control-by-price of distributed energy resources and flexible demand”, IEEE Trans. on Smart Grid, Vol.2, No.2, pp.334-341 (2011)
- [62] Z. Cstvei, J. Ostergaard, and P. Nyeng: “Controlling price-responsive heat pumps for overload elimination in distribution systems”, in Proc. IEEE Innovative Smart Grid Technologies, ISGT Europe 2011 (2011)
- [63] 蟙川忠三：「ADR アグリゲーションとビル設備電力管理システム」，電気設備学会誌，Vol.33, pp.40-43 (2013)
- [64] 蟙川忠三：「電力市場構造とデマンドレスポンス —リアルタイム電力料金とシステム制御安定性—」，電気設備学会誌，Vol.33, No.9, pp.3-6 (2013)
- [65] A. Kiyota, M. Takahama, C. Ninagawa: “Wide Area Network Discrete Feedback Control on FastADR of a Cluster of Building Air-conditioning Facilities”, IEEJ Trans. on Electrical and Electronic Engineering, Vol.11, No.6, pp.826-828 (2015)

- [66] H. Asaka, M. Takahama, C. Ninagawa: “Mitigation of Saturated LFC Thermal Power Plants by Very Fast ADR Aggregation of a Huge Number of Building Multi-Type Air-Conditioners”, IEEJ Trans. on Electrical and Electronic Engineering, Vol.12, No.3, pp.442-443 (2017)
- [67] 蟻川忠三, 安積英駿, 高浜盛雄 :「ビルマルチ空調設備群 FastADR 閉ループ制御のための非対称定率増減伝達関数モデル」, 電気学会論文誌 B, Vol.137, No.8, pp.566-572 (2017)
- [68] J. Morikawa, T. Yamaguchi, C. Ninagawa: “Smart Grid Real-Time Pricing Optimization Management on Power Consumption of Office Multi-type Air-conditioners”, IEEE Trans. on Electrical and Electronic Engineering, Vol.11, No.6, pp823-825 (2016)
- [69] 森川純次, 蟻川忠三 :「ビル用マルチ空調設備の電力制限と室温維持を時系列調整する高速リアルタイム電力料金最適制御」, 電気学会論文誌 B, Vol. 136, No.11, pp.817-823 (2016)
- [70] 蟻川忠三, 森川純次 :「ビルマルチ空調群デマンドレスポンス過渡応答の大量アグリゲーション均し効果の推定」, 電気学会電力系統技術研究会, PSE-17-120, pp.97-102 (2017)
- [71] S. Noh, J. Yun, K. Kim: “An Efficient Building Air-Conditioning System Control Under Real-Time Pricing”, 2011 Int. Conf. on Advanced Power System Automation and Protection, pp.1283-1286 (2011)
- [72] S. Ramdasapalli, M. Pipattanasomporn, M. Kuzlu, S. Rahman: “Transactive Control for Efficient Operation of Commercial Buildings”, IEEE Innovative Smart Grid Technologies Europe ISGTEurope, pp.1-5 (2016)
- [73] J. Aguero, F. Rodriguez, M. Castilla, M. Pereira: “Productiveness and Real Time Prices in Energy Management for HVAC Systems”, 39th IEEE Conf. on Industrial Electronics IECON2013, pp.7956-7961 (2013)
- [74] I. Murata, Y. Takarada: “Modeling of Dynamics in Demand Response for Real-Time Pricing”, IEEE Int. Conf. on Smart Grid Communications, pp.806-811 (2014)
- [75] 田丸慎吾, 村山大, 村井雅彦, 高木康夫, 花田雄一, 木村浩二 :「外調機とビルマルチエアコンから構成される空調システムの省エネ制御手法」, 平成 26 年電気学会全国大会, Vol.4, pp.337-228 (2013)

- [76] 三宅範幸, 高橋広考, 富田泰志, 桑原健一:「蓄電池とビル設備の協調型電力需要ピークカット制御手法の開発」, 平成25年電気学会電力・エネルギー部門大会, pp.31_7-31_8 (2013)
- [77] 奈良村拓, 森川純次, 蟻川忠三:「ビルマルチ空調設備のFastADRにおける電力制限量配分のための室温副作用予測モデル」, 電気学会論文誌B, Vol.136, No.4, pp.432-438, (2016)
- [78] S. Kondo, J. Morikawa, C. Ninagawa: "Averaging Effect on Stochastic Response Prediction in FastADR Aggregation for Building Air-conditioning Facilities", IEEJ Trans. on Electrical and Electronic Engineering, Vol.11, pp.820-822 (2016)
- [79] C. Ninagawa, S. Kondo, J. Morikawa, "Prediction of Aggregated Power Curtailment of Smart Grid Demand Response of A Large Number of Building Air-Conditioners", IEEE Int. Conf. on Industrial Informatics and Computer Systems (CIICS2016), pp.1-6, Dubai, UAE (2016)
- [80] C. Ninagawa, A. Nakamura, J. Morikawa: "Modulation Training Method of Perdition Model for Smart Grid FastADR Power Limitation of Building Air-conditioners", IEEJ Trans. on Electrical and Electronic Engineering, Vol.13, No.2, (2018)
- [81] 電力需給解析モデル標準化調査専門委員会:「電力需給・周波数シミュレーションの標準解析モデル」, 電気学会技術報告, No.1386, pp.108 (2016)
- [82] W. Feller: "An Introduction to Probability Theory and Its Applications Third Edition", John Wiley & Sons, New York (1968)
- [83] 蟻川忠三, 山田倫久:「OpenADRによるデマンドレスポンス通信」, 森北出版, (2020)
- [84] Y. Aoki, K. Suzuki, C. Ninagawa, J. Morikawa: "Averaging Effect Model on Aggrigation Margin of Fast Demand Responses of Building Multi-type Air-conditioners" in IEEE International Conference on Industrial Technology, ICIT 2019, pp.1274-1279, Melbourne, Australia (2019)
- [85] 青木佳史, 伊藤大道, 蟻川忠三, 森川純次, 稲葉隆, 近藤成治:「リアルタイム電力料金に適応するビルマルチ空調の全館電力制限と優先部分室温の複合調整制御」, 電気学会論文誌D, 138巻, 第10号, pp.777-786 (2018)
- [86] 青木佳史, 任側忠三, 森川純次, 河西竜也, 近藤成治:「電力エネルギーサービス機械学習アルゴリズム開発用のビルマルチ空調設備エミュレータ」, 電気学会研究会資料, ST-19-39, SMF-19-64, pp.61-66 (2019)

- [87] S. Matsukawa, C. Ninagawa, J. Morikawa, T. Inaba, S. Kondo: “Stable Segment Method for Multiple Linear Regression on Baseline Estimation for Smart Grid Fast Automated Demand Response”, in IEEE Innovative Smart Grid Technologies ISGT-Asia, pp.2571-2576, Chengdu, China (2019)
- [88] 後藤聰, 青木佳史, 蟻川忠三, 森川純次, 近藤成治:「リアルタイム電力料金に適応するビル空調制御のエミュレータ転移強化学習」, 電気学会研究会資料, ST-20-20, pp.1-6 (2020)
- [89] 電力中央研究所:「米国における家庭用デマンドレスポンス・プログラムの現状と展望- パイロットプログラムの評価と本格導入における課題-」, 電力中央研究所調査報告,Y10005 (2011)
- [90] Morgan, Nelson, Hervé Bourlard: “Generalization and parameter estimation in feedforward nets: Some experiments.”, Advances in neural information processing systems 2, Vol. 2, pp.630-637 (1989)