



Title	データ包絡分析法によるオフィスビルの空調運用改善に関する研究
Author(s)	森嶋, 武史
Citation	大阪大学, 2023, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/91981
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

データ包絡分析法による
オフィスの空調運用改善に関する研究

提出先 大阪大学大学院情報科学研究科

提出年月 2023年1月

森 鳩 武 史

研究業績

A. 学術論文誌論文

- Morinibu, T. and Morita, H. Improving operation management performance of air conditioners in offices using data envelopment analysis, Journal of Building Engineering, Volume 57, 2022.

B. 学会講演

- “DEA と回帰モデルによるオフィスビルのエネルギー消費量削減とエネルギー効率向上が有効なターゲットの特定”, 日本オペレーションズ・リサーチ学会 第 93 回「評価の OR, 講演 1 (2021).
- “Data envelopment analysis によるオフィスビル空調運用改善”, 日本オペレーションズ・リサーチ学会 秋季研究発表会 (2022).

C. オープンソースソフトウェア開発

- “Pyfrontier ”, <https://pypi.org/project/Pyfrontier/>

内容梗概

空調システムはビルエネルギーの大部分を占めるため、効率的な運用によってエネルギー使用量の多くを削減できる。いくつかの先行研究は、人感センサー等と連動させることで空調システムの運用を最適化し、無駄に稼働されている運転時間を減らすことで効率的なエネルギー運用を達成している。しかしながら、これらの研究はセンサーと連動できる先進的なビルが前提となっている。そこで本論はエネルギーマネジメント施策の適用範囲を広げるため、少なくとも空調機器の運転データを保持しているビルを対象として、エネルギー削減可能性の探索とその実現方法を提案する。

提案手法は、空調システムの運用方法が日によって異なることに着目することで、データ包絡分析法によって効率的に操作されていた日を特定し、改善すべき日とその改善量を明らかにする。その際、空調運用時間の抑制は、快適性に悪影響を与える可能性があり、ユーザーやビルオーナーの納得性も必要であるため、改善の実現可能性を重要視することで、無理のない改善策法を見つける。この際、段階的な改善方法として、層を越えるクロスレイヤー構造を取り入れ、改善目標を選択する指標として魅力度と発展度を適用させる。また、改善における制約については、固定的な制約と変動的な制約の二つに対して比較を行なう。さらに、得られた分析法の結果を解釈することで、実際にどのように空調運用の改善を行うことができるかを明らかにする。

本手法をあるオフィスビルに対し適用した結果、使用時間のおよそ7.5%について削減可能性があることがわかった。また、その結果を用いて実際に空調管理システムへ設定を反映することで、ユーザーやビルオーナーへの空調運用改善に対する示唆を与えた。本手法は、空調機器の運転履歴から無駄となっている可能性のある運用を明らかにしたという点で先進的であり、省エネ施策のターゲットを先進的なビルからより一般的なビルに広げたという点で、ビルのエネルギーマネジメント領域の拡大と発展に寄与する。また、本提案手法の適用先は、段階的な改善のうち、改善と改善の間に時間的な期間が空き、その間にデータが更新される可能性を加味した問題設定である。この前提を満たす領域であれば、本手法は空調分野に限定されことなくあらゆる分野で適用可能である。

目次

1	緒論	5
1.1	エネルギー効率的なビルの実現方法	5
1.2	ビルエネルギーの評価手法	9
1.3	空調運用のエネルギーマネジメント	13
1.3.1	実務の観点による調査	13
1.3.2	システムの観点による調査	17
1.4	本研究の貢献	19
1.5	本論文の構成	20
2	本研究において前提となる知識	21
2.1	データ包絡分析法 (DEA)	21
2.2	Context-dependent DEA	23
2.3	DEA における段階的な改善経路	26
2.4	DEA の結果を活用する分析	32
3	DEA による実現可能性を考慮した空調運用の改善	36
3.1	本手法の特徴と応用先	36
3.2	空調運用データの扱い方	37
3.3	実現可能性の高い改善日の特定	39
3.4	結果を用いたエネルギーマネジメント	44
4	ケーススタディ	47
4.1	実行手順とデータ	47
4.2	適用結果	55
4.2.1	全 DMU の改善経路とクラス分類結果	57
4.2.2	各クラスの詳細分析	60
5	討論	69
5.1	ケーススタディから得た知見	69
5.2	適用の制約と今後の課題	69
5.3	結論	71
6	付録 オープンソースソフトウェア開発	73
6.1	背景	73

6.2	DEA ライブラリ Pyfrontier	74
6.3	おわりに	77

1 緒論

1.1 エネルギー効率的なビルの実現方法

エネルギー効率性や気候変動は世界共通の重要な課題であり、代替エネルギーである非化石燃料への移行が進められている。一方で、化石燃料は主要なエネルギーとして未だ増加傾向にあり、エネルギー使用量を削減する施策を行うことは依然として重要である [1], [2]。世界で消費されているエネルギーのうちビルエネルギーは主要であり、日本では25%、スペインは23%、中国は28%、EUは37%、UKは39%、ブラジルは42%、スウェーデンでは47%のように、各国それぞれ割合は異なるが非常に多くの割合を占めている [3]–[5]。そのためビルエネルギーの運用改善は、エネルギー削減を実現するための重要な要因の一つであると考えられており、様々な研究や取り組みが行われている。特に空調制御はそのビルエネルギーのおよそ40%を占めているため、エネルギー削減を効果的に行うためには重要な領域である [6]。

エネルギー効率的な空調制御を実現するためには、図1が示すように、効率的な機器の導入、革新的なシステム構成、運用マネジメントと制御の三つに大きく分類される [7]。効率的な機器の導入や革新的なシステム構成については快適性を阻害する可能性は低いが、運用のマネジメントやその制御の高度化は、熱処理量を減らし、いくことになるため、快適性を低下させる可能性について注意する必要がある。




図 1: エネルギー効率的な空調を実現するための方法 [7]

先行研究によると、ビルの環境を改善することは1500万人もの従業員の健康を向上できるとされており、エネルギー削減施策は、快適性を犠牲にすることなく実行すべきとされている [8]。また、継続的なエネルギーマネジメントを実現するためには、図 1 が示す各領域の関連性も重要であり、ビルのライフサイクルを通して改善することも重要であると指摘されている [9]。

古くからの空調制御では室内温度や湿度に対してのみの制御が行われており、これは非効率的なエネルギーの使用につながっていた。たとえば、その部屋に人が居るかどうかに関わらず、22 度の温度に制御するなどである。より効率的な運用のためには、居住者の情報を用いることが最も有効な手段の一つであると言われており [10]、その効果の大きさから、センサーを活用した動的な制御による最適化の対象にもなっている [11]。より高度な技術を用いた制御については、様々な情報をもとに効果的な熱処理を行うため、深層強化学習を用いた手法が研究されている [12]。また、快適性を向上させるため、放射温度に焦点を当てた制御も提案されている [13]。これらはブラックボックスモデルであるが、モデルベースとしながらもパラメータを推定するようなモデルによって熱負荷を予測することで制御に反映する研究も行われている [14]。しかし、これら学習モデルを用いる場合には学習にはシミュレーション上のデータが用いられるため、実測の結果の違いをどのように吸収するかが課題である。学習モデルによる設置環境に適応した制御は、先行研究の調査結果によって分類が行われ、様々なセンサーや制御へ適用するためのフレームワークも提案されており、実際の適用段階へと近づいている [15]。このように運用や制御においては、冷凍サイクルの効率化を行うことから拡張して、熱処理の必要性や居住者の情報を加味する制御が提案されてきた。

このように、より効率的な空調制御のためには居住者情報が有効に用いられているが、居住者の行動が実際にエネルギー使用量にどのように影響しているのかをここでは明らかにする。本論で扱う居住者とは、該当時間内に指定場所を占有する人のことを指し、特にオフィスビルにおいては従業員のことを指し、一般にはユーザーを指す。照明についての調査では、業務中において不要な照明の点灯時間は、デスクから照明のスイッチに手が届かないことによる物理的な障害によっても引き起こされることが明らかになった [16]。また、業務中の従業員についての調査が行われ、48 時間に及ぶ記録ではおよそ 50% の時間は従業員は自身のワークスペース以外で過ごしていることがわかった [17]。これらは、ワークスペースで過ごしている時間のエネルギー使用方法を効率化する影響より、そもそも必要とされていない時間帯の照明や空調制御のエネルギーの影響の方が大きい可能性を示唆している。

実際に、多くの既設ビルは固定化されたスケジュール設定の運用であり、このよ

うな居住者が実際にどのように空調機器などを利用しているかは、ほとんど加味されていない。それは、ビルに設置されているセンサーは荒く不正確であるのが現状であり、照明の制御のみに使われているのが一般であることが、要因の一つとして挙げられている。例えば、Passive infrared (PIR) ベースのセンサーは動作を検知して照明制御には用いることができるが、居住者数を判定することは難しい。PIR 以外のより高度なカメラやソナーによる手法もあるが、実装難易度やコスト課題、プライバシーの問題から社会実装は難しいと言われている [18], [19]。このような居住者情報を用いる空調制御方法はいくつか提案されているが、上記のようにリアルタイムに正確な居住者数を取得することは技術的にも難しいため、結果として事前に決められたスケジュール運転を行うことが多いことが調査によって明らかになっている [20], [21]。

上記に示したデータ取得と利用の難しさが残る一方で、居住者による情報を加味した制御によるエネルギー削減効果は非常に大きいため、このような研究は数多く行われている。Nguyen ら [22] による調査では、実際の値は実証しなければ明らかにはないが、シミュレーションを用いている既存の文献を分析することによって、居住者ベース制御は空調システムにおいて、10-40%ものエネルギー節約をもたらす可能性があることを明らかにした。その中でも Agarwal らは、PIR とドア開閉の記録を組み合わせることで、より正確な在籍者数を観測することを可能にし、それをもとにシミュレーションを実施することで空調機器のエネルギー消費量を 10-15%ほど削減できることを示した [10]。このように、実は必要とされていないエネルギーの消費量は、空調以外も含めるとビル全体の 50%にものぼると言われている [23]。このような研究によって、データ取得の難しさは緩和され、より簡易な方法で居住者のデータを活用して空調制御を効率化する技術は実現に近づいている。

しかしながら、居住者情報の活用がより簡易になったとしても、その情報を収集して空調機器と連動させて制御を行うためには依然として導入のための壁が残る。それはセンサー情報を収集して、空調機器への制御をコントロールする管理システムである。先述したような制御技術を実現するためには、各機器に制御司令を出してそれらを管理するシステムが必要であり、そのシステムや方法については様々な概念が用いられる。たとえば、Building Management System (BMS), Building Control System (BCS)、Building Automation System (BAS) などがあるが、Building automation and control systems (BACS) がビル全般を管理するシステムを示す一般的な概念として用いられることが多い。明確に区別されるのは、BMS や BCS は BACS と異なり必ずしも自動化を含まないということである。本論では次の用語との比較のため、BMS を基本的なビル管理システムの用語として用いる。この BMS を拡張した概念

として、Intelligent Building Management System (IBMS) があり、IBMS は BMS に比べ、新しいセンシング技術や拡張技術とともに成長できるため、スマートデータセンサーや IoT 接続されたオフィス機器、ビデオ会議などのツールが追加されても、それらをすべて中央のプラットフォームから制御することが可能になる。BMS は、朝の決まった時間に暖房や照明をつけることができるが、IBMS はもっと複雑なロジックで、より細かい制御を実現することができる。例えば IBMS は、特定の人が入ってくると暖房や照明をつけ、その人の好みに合わせて明るさや温度レベルを調整することができる。このように建物内の快適な環境を維持しながらエネルギー消費を削減することは相反する目標であり、IBMS のようなインテリジェントなシステム設計を必要とすると言われている [24]。つまり、これまでに紹介されている高度な空調制御を実現するには、IBMS などの高機能な管理システムが必要であり、BMS などを導入している既設ビルでは適用が難しいということが、もう一つの導入における障壁である。

さらにこのようなエネルギー削減施策は、仮に技術的に可能であったとしても、ビル所有者が導入を受け入れるためには、費用対効果の側面も考慮しなければならないという課題もある。そのような背景のもとでは、家庭用空調のエネルギーマネジメントに対する研究で、エネルギー削減効果が大きいと見込まれる省エネ施策の提案先を分析によって明らかにすることで、リソース効率を高める手法が提案された [25]。ビルの場合はその規模によって、家庭用よりも大きな影響をあたえる可能性があるが、同様に省エネ施策の効果を簡易的に得ることが有効と考えられる。その試算結果を考慮した上で、簡易的な施策から実行するのか、もしくは本格的なシステムの導入を進めるのか、という意味決定が行われると想定されるため、より少ない条件で実施可能であるエネルギー改善手法を研究することは、ターゲットを適切に選ぶための情報を与えるという点と、先進的な制御の導入を効果的に行うためにも有効である。より現実的な方法としての省エネルギー施策はたとえば、従業員の行動を改善することによる施策である。利用方法によってエネルギー消費量を節約することは、多くの場合は高機能な制御によるエネルギー削減よりも効果が大きく、高度な技術や大きなコストを要することもなく、既設ビル、新設ビルを問わず適用できると期待されている [23]。以上の議論をもとにして、本論では居住者情報に着目したより簡易な省エネ施策を実施するための研究を行う。

1.2 ビルエネルギーの評価手法

本研究は 1.1 章で紹介したように、より少ない条件で実施可能なエネルギー改善施策を主目的とすることで、ビルエネルギーにおける省エネ施策の幅を広げる。そのために本章は、ビルのエネルギーを評価するための先行研究を調査し、より簡易に実行できる手法とその探求を行う。

ビルのエネルギー効率性の評価値は、そのスコアが低いビルを省エネ施策のターゲットにしてあらゆる運用を改善するために用いられている [26]。そのスコアを測る手法は、表 1 に示すように、シミュレーション、統計、機械学習などが提案され、それぞれの強みや応用上の制約などがまとめられている [27]。中でもデータ包絡分析法 (data envelopment analysis; DEA) はノンパラメトリックな手法で、多入力、多出力のデータの効率性を測るために広く用いられている [28]。DEA は表 1 によると、他の手法に比べて前提とする情報や状況の制限が少ないという意味では、実行が比較的容易である。ただし、DEA の効率値はシミュレーションや回帰モデルのようにエネルギー使用量を表すわけではないため、ユーザーやオーナーが直接理解しやすい結果ではない。そういった理由で、DEA の効率値の利用は主にデータを扱う分析担当者などに限られている。本研究においては DEA の結果の利用方法を工夫することで、理解が難しい値であるというデメリットを抑えつつ、実行容易性のメリットを活かした手法を提案する。

DEA はサービス産業における生産性の向上に対して優れた成果を上げており、図 2 は 2003 年から 2020 年までの DEA の応用文献の分野の割合を示すが、特に輸送やサービス産業が多くを占める。その中でも、エネルギーや環境全般に関する DEA の応用は、表 2 が示すように近年増え続けている [29]。特にエネルギー効率化・削減については近年最も増加率が高く、エネルギーの分野の中でも重要視され、活発に応用研究が進んでいることがわかる。また、ビルエネルギーの分野でも、多入力多出力のデータを扱えるという特徴により応用が進んでいる。

DEA において decision making unit (DMU) は、市、政府、銀行、大学、病院、会社などを含むあらゆる事業体のことを示し、効率性を測る対象のことである。ビルエネルギーにおける応用では、DMU は入力を電力使用量、出力をそのビルが持つ設備の数のように用いられることが多い。初期に応用された例では、入力を energy use intensity (EUI)、出力を収入と在籍者割合として用いられた [31]。

他には EUI に対する回帰モデルを作成し、その誤差を DEA によって評価する手法も提案された [32]。この場合、入力値に観測値、出力に予測値を用いることで、予測した値よりも大きい実測になっているデータは非効率的とみなされる。これは回帰モデルが全体の傾向を示す指標であるため、全体の傾向としては予測値になる

表 1: 評価手法

手段	仮定	優位性	制限
シミュレーション	理論上のエネルギー消費量をシミュレーションにより算出できる。	多岐にわたる要因とパラメータに対して影響度合いを測ることができる。	建物の詳細な情報が必要である。専門的な技術者に強く依存した結果になる。
線形回帰モデル	エネルギー消費量と説明変数に線形関係を前提とする。回帰誤差は正規分布であり独立である。	エネルギー消費に強く影響を与える要因がわかる。説明変数とエネルギー消費量の関係を調査できる。	仮定を満たす必要がある。
Artificial neural networks	過去に取得されたデータをもとに入出力の関係を学習する必要がある。入力と出力の間は非線形的な関係を仮定する。	より正確な予測を提供できる。ビルエネルギー消費量に対して任意の関数のマッピングができる。	大量の観測データが必要になる。
DEA	多入力多出力の関係に関数関係の前提をおかない。	異なる領域のデータをパフォーマンスの評価に加味できる。大量のデータを扱える。	外れ値に強い影響を受ける。

表 2: DEA のエネルギー分野での応用研究数の推移 [29]

応用研究	トピック	合計	1980 年	1990 年	2000 年	2010 年
エネルギー	電力	185	3	16	55	111
	石油	23	0	2	6	15
	石炭	7	1	1	2	3
	ガス	13	0	0	4	9
	熱	3	0	0	3	0
	再生可能	36	0	0	3	33
	効率化・削減	140	0	1	21	118
全て	全て	407	4	20	94	289




図 2: 2003 年から 2020 年までの DEA の応用文献の分野の割合 [30]

はずが、実態は実測値の方が大きくなっていることを意味しており、改善の余地がある可能性を提示する。図 3 が示すように、この場合は 1 入力 1 出力となるので、DEA の多入力と多出力を扱える強みは活かしきれない。

ビルエネルギーにおける DEA の応用の歴史では、三つの課題が挙げられており、表 3 はそれら文献をまとめている。まず指摘されたのは外れ値の影響である。DEA は入出力をもつ多くのデータ点によって効率的フロンティアが決定されるため、一つの外れ値が効率的フロンティアを劇的に変えてしまう。そしてその結果、ほとん

表 3: ビルエネルギーに対する DEA の応用手法の比較

手法	[31]	[32]	[33]	[34]	[35]	[36]
外れ値の抽出				✓	✓	✓
EUI の利用	✓	✓		✓	✓	
制御不可能である要因の切り分け						✓




図 3: 予測値と実測値による DEA の効率性評価 [32]。青線が Constant returns to scale、赤線が Variable returns to scale により構成されたフロンティアを示す。

ど全てが効率的と判断されたり、非効率的と判断されてしまうことによって、正確な分析を阻害することが指摘されている [37], [38]。Banker と Chan は、設備管理者や建物オーナーは、ビルの実際のエネルギー使用量が DEA の結果に反映されていないことに直感的に気づいた場合、DEA のベンチマークツールを信頼しないことにつながることを示し、結果の信頼性のために外れ値の検出が重要であることを指摘した [39]。また外れ値の影響によって、リソースを割くべきエネルギー削減の方向がずれてしまうと、効率的な対象への施策実施が行えないという機会損失につながってしまうため、避ける必要がある。このような外れ値を取り除く方法は、外れ値を Super-efficient outliers として検出して取り除く手法が提案された [40]。これらは後にビルエネルギーへの応用の際にも用いられた [34]。

次に、入力に用いる値に対しても問題提起が行われた。いくつかの先行研究は EUI を DEA の入力値として用いていた [31], [32], [34], [35]。しかし EUI のような割合値が入力に用いられると、DEA において重要な生産可能集合の凸性が成り立たないと指摘されている [41]。これは正しくない効率性のスコアを算出してしまうことに繋がり [42]、応用上は非効率的なビルを効率的と判断してしまうことで、本来は非効率的なビルを改善の機会から除外してしまうので、入力として用いるには避けることが望ましい。これを避けるためには、割合値を構成する値をそれぞれ DEA の入力と出力に追加するという手段が提案されている。

最後に、これらの問題に加え、これまでの研究では制御不可能な要因を区別していなかったことが指摘された [36]。設備管理者は外気温やビルの部屋数などはコントロールできないため、制御可能な値と不可能な値の区別は重要である。これは DEA においては裁量権のない要因として扱われ、包絡モデルと密接に関わっている [43]。この区別がない場合、実際に入力や出力値に改善を行うことが難しくなるため、応用上の大きな課題となり、実際に提供された改善提案を実現することが現実的に不可能となる。外れ値や割合値、制御不可能要因はビルエネルギー特有の課題ではないが、この領域では特に課題意識を持って取り組まれてきた要因であるため、応用上影響力が強い要因であると考えられる。

これら DEA の分析結果は表 1 のエネルギーシミュレーションのモデルを置き換えるものではなく、省エネ施策の対象とするビルを選定するためのランク付を行うものであるとされ、限られたデータしか存在しなかったり扱うことができない状態のビルに対して、設備管理者が運用を改善するための初期段階に用いられるとしている [36]。表 3 がとりまとめている先行文献も、DEA の結果の利用に対しては同様の見解である。また、先行研究はこれ以上には DEA の結果の活用方法には言及しておらず、実際にどのようにエネルギーマネジメントの改善を実施するかという議題については触れていない。

一方で、空調機器に特化した DEA の応用については、チラーシステムに対して coefficient of performance (COP) の回帰モデルの残差を評価する手法が提案された [44]。これは Lee [32] の手法を踏襲したものである。彼らは運転時刻毎のデータを DMU と定義し、どの時間帯の運転状況が良かったのかを評価することで、システム効率の改善余地を算出した。他には、床置き空調機器に対し、設置条件に対する効率性を評価するという応用事例がある [45]。我々の知る限り、ユーザーの空調の運用方法に焦点を当てた DEA の応用事例は明らかにはなっていない。DEA はビルエネルギーの評価を行う手法の中では比較的簡易な手法であるが、その応用は空調の運用方法のデータまで用いられてはいなかった。

1.3 空調運用のエネルギーマネジメント

1.3.1 実務の観点による調査

本章では、実際のエネルギーマネジメントのフローや内容を調査することで、空調運用に焦点を当てて DEA を効果的に適用する際に、必要とされる条件や有効な知見を明らかにする。まず実務の調査対象としてはオフィスビルを対象とする。なぜなら、設備運転管理者とビルのオーナーシップが近いからであり、この場合は空




図 4: 外部の専門家によるビルへのエネルギーマネジメントの適用フロー

調機器の運用の省エネによる電力料金の削減は、直接的にビルオーナーの利益になるため、省エネ施策を導入しやすく効果的であるからである。逆にテナントビルのような物件は、電力料金の費用会計やオーナーシップの関係上、省エネ施策を適用するのは非常に難しい。また、対象とするオフィスビルにはIBMSのような先進的な取り組みが導入されていないとする。なぜなら本研究の主目的は省エネ施策の幅を広げることだからである。このような条件の既設ビルであっても、空調機器の運用改善や古い機器を高効率機器に交換することによって省エネルギー化を実現することが可能である。しかし、実際にエネルギーマネジメントを実行する場合、実現可能性とは別に技術的な課題が存在する。日本においては日々の運転は設備運転管理者が行っているのが一般的であるが、設備運転管理者は外部の専門会社が担当している場合が多く、設備運転や保守・点検業務を通じて安定的にエネルギーを供給するのを目的としている。その設備運転の目的は利用者からのクレームがないことであり、積極的な省エネ実施までには及んでいないのが現状である。そのため、運用に関する省エネ施策の実施者は、外部の専門家が中心であることが多い。

外部の専門家は実際に、図 4 のようなフローで省エネ運用をサービスとして提供することで、設備運転管理者単体では実施できない施策を実行している。専門家がまず行うことは、蓄積された空調機器の運用データから、エネルギーを無駄に使用しているかどうかを探し出し、それらを顧客である建物オーナーに提案することで




図 5: 冷房期間の各室内機の時刻毎の運用時間。濃い青色は運転時間のうち、室内機が熱交換していた時間を示す。

ある。ここでは、専門家による提案とオーナーによるすり合わせが行われる。専門家はデータを参照して削減できそうな時間帯に停止制御を入れるなどを提案するが、それはユーザー側であるオーナーからすると利用意図があって用いている場合もあるので認識の齟齬が発生する。これらを一つ一つの室内機毎に議論しながら、可能な範囲で制御設定の合意を取り導入しているのが現状である。こういった業務構造は海外においても存在する。

専門家によるエネルギーマネジメントには、従量電力量による使用料金の削減と、年間の最大電力であるデマンド値によって決まる基本料金の削減という二つの方法が存在する。従量電力については、空調機器が使われる時間を減らしたり、温度設定を弱めることで対処する。図 5 はある室内機の運転状況のヒストグラムを示す。この図を参照しながら、使用時間の削減や冷房時の低すぎる設定温度を緩和できないか分析する。デマンド値は図 6 や図 7 のように、30 分毎のデマンド値の年間の最大値を確認し、その値が突出しないように機器の能力制御を設定することで抑えられる。デマンド値は国によって計測方法が異なるが、その値によって料金が決まるというのは概ね各国共通である。デマンド値については値を事前に予測する研究が行われており、たとえば事前に運転制御をすることで最大値を回避することで基本料金を抑えることもできるなど、予測値は様々な用途で用いられる [46]。

課題は、現状の専門家による分析ではユーザーが実際に使用時間や温度設定を緩和できるかどうか、という観点を弱く見積もるため、ユーザーとの間に齟齬が発生しやすいことである。とくにこの問題は使用方法を見直すという従量料金の削減に



図 6: 全空調エネルギーの 30 分毎の最大値のランキング




図 7: ある日の 30 分毎の合計空調電力の最大値。PAC-1 はある空調機器の使用電力量を示す。

において顕著であり、ユーザーが受け入れやすい削減提案を提供できることは、図 4 の合意フェーズを形成しやすくすることができるため、よりスムーズな省エネ施策の実施のために有効である。またこれら専門家による分析の工数も課題である。以上の観点から、エネルギーマネジメント施策を実施する上で、空調機器の運用量の削減提案の受け入れやすさは重要である。

1.3.2 システムの観点による調査

空調運用のエネルギーマネジメントを考える場合、それらを構成するシステムについての理解も必要であるため、本章ではシステムの観点からの調査を行う。Variable refrigerant flow (VRF) は、1980 年代に日本で導入されたビル用マルチエアコンであり、複数の室内機で構成されるシステムである。その後、とくにアジア圏の中小規模のオフィスビルで個別制御性やメンテナンス容易性のために広く広まっている [47]–[49]。そのため、日本の中小規模のオフィスビルをターゲットとする場合には VRF システムを扱うことになる。VRF システムはダクトエアコンに比べ、ダクトによるエネルギーのロスや導入の簡易性、室内機の組み合わせの柔軟性に利点があり [50]、さらに複数の室内機と冷媒流量の制御を行うことによって、それぞれの居住者の温度快適性を提供することができる [51]。図 8 は一例として、VRF システムのスケッチを示す。このように、一つの VRF システムはその室内機の配置を複数の部屋にすることで、複数の部屋に対して同時に制御することもできるという設置上




図 8: VRF システムを構成する要素と設置先の部屋のイメージ図

の柔軟性も利点である。VRF システムはさらに効率的な制御や運用の研究が継続的に行われている [52]。

1.1 章で扱ったように、居住者の行動はエネルギー削減の可能性に大きく影響するため、そのような行動履歴が VRF システムでどのように表現されるかを明らかにすることは重要である。本研究で扱う居住者行動とはユーザーの行動であり、ある期間中における従業員による機器操作の行動のことである。より具体的には、空調機器がオンになっていた時間、オンオフの回数などである。調査によると、ユーザーの行動はダクト式の空調の場合には3倍ものエネルギー消費量の差を生むことが明らかにされた [53]。このユーザーの行動は、シミュレーションによってビルのエネルギーパフォーマンスを予測する際には加味されないため、実際に運用した際の値との誤差をもたらす可能性があるとして指摘された [54]。しかし、このユーザーの行動による影響は今まで VRF システムにおいてはほとんど調査されていなかった。Zhang らはこのユーザーの行動による影響を VRF システムにおいて調査し、オフィスビルにおける VRF システムの各室内機は、多様なオンオフサイクルを持つことを示した [55]。さらに彼らは、継続して運転し続けると仮定した場合のエネルギー使用量は、このユーザーの室温快適性の要望の違いがもたらす制御のオンオフサイクルによって、実際のエネルギー使用量よりも 1.8 倍ほど多くなることを示した。つまり、居住者による空調機器の操作はエネルギーを削減する方向であり、無駄な運転を停止・制御することであり、その結果シミュレーション上の結果との差異を発生させるということである。

本論のアイデアはこの結果をもとにして作成された。居住者による空調操作がエネルギーを削減するものであるなら、ユーザーの空調機器の操作は常に一定ではないため、その違いを見ることによって空調機器の運用を改善する情報を抽出することができるのではないかとということである。各室内機はユーザーによって制御されるので、各日によって運用が異なる場合がある。図 9 はあるオフィスの冷房期間における二つの室内機の日毎の総運用時間を示す。運用時間は、ユーザーが指定の室温にするために室内機を起動していた時間であり、室内機が実際に能力を出した時間ではない。この図は実際に日毎の運用時間に差が見られたことを示す。この原因を見つけるのは容易でないが、実際に少ない運用時間で稼働していた日があることは事実である。この少ない運用時間の日は、他の各日が参考にすべき省エネルギー運用である可能性がある。これら少ない運用時間の日が理想的な省エネルギー運用方法であるとする、より長い運用時間の日との差は無駄になっている可能性のある運用を探すヒントになる。この仮説を検証するためには、良い運転の日とそうでない日を評価する必要がある。




図 9: 冷房期間における各室内機の総運用時間の散布図。各点は日毎の総運転時間を示し、赤い丸は特に短い運用時間であった点を示す。

1.4 本研究の貢献

本研究はエネルギーマネジメントの分野において、より一般的なビルを対象とした省エネ施策を提案するという点で貢献する。それは、より少ない条件で適用可能なエネルギー削減施策を探索することは、エネルギー削減施策を広く展開するという意味で有効であるためである。ビルエネルギー評価においては、より簡易的な条件で適用できる手法としては DEA が用いられていたが、空調運用の領域に焦点をあてた研究事例は我々が調査した限りでは存在しなかった。そのため本研究は、空調運用履歴のデータに対して DEA を適用する際の DMU の構成や観点についても、新たな事例を与えるという意味で価値がある。さらに DEA を適用する際には、空調運用に関するエネルギーマネジメントの観点から、提案の受け入れやすさを重要視する必要がある。そこで必要な観点となるのは提案の実現可能性である。本研究ではその実現可能性についても、DEA の改善経路の研究を応用することで、改善経路を見つけるための方法を提案している。また、この提案手法は、空調分野に限定されることなく適用することができる。具体的には、段階的な改善を前提とするが、その改善の際にデータが更新される可能性を含めた問題設定の場合に効果的である。

1.5 本論文の構成

本論文は、第1章でまず、エネルギー効率的なビルエネルギーを実現するためにどのような研究が行われているのかを示した。特にビルエネルギーの分野では、エネルギー削減施策のためのベンチマークとしてDEAが用いられている例を取り上げ、先行研究をとりまとめた。その際、外れ値や割合値について適切に処理が行われ、制御できない項目の区別が行われていた。本章の最後では、エネルギー効率的なビル実現のための調査結果と、ベンチマークとしてのDEAの応用事例をもとに、本研究がどのような課題意識で何を実現することで、この分野にどのように貢献するのかを明らかにした。

次の第2章では、本研究の提案手法で前提となる、DEAの改善経路とDEAの結果の利用についてまとめる。ここではビルエネルギーの分野からは離れ、様々な分野におけるDEAの提案の実現可能性や結果の利用方法に対して、いくつかの重要な先行研究について触れる。

第3章では、第2章をもとに、DEAによる実現可能性を考慮した空調運用の改善手法を提案する。ここでは空調運用の観点から、改善候補を見つけるための制約条件を付与したり、改善目標の選定基準を作成する。さらに、DEAの結果を利用して、実際に省エネルギー施策を実施するための知見を抽出する方法を提案する。

第4章では、提案手法をあるオフィスビルに実際に適用して、省エネルギー施策の実施にいたるまでの結果をとりまとめる。これは、提案手法の有効性の検証と、実際の適用による課題の発見のために行う。

第5章では、本論文全体にわたる討論として、ケーススタディによって得た知見や、本手法の制約や課題についてとりまとめ、結論として総括を述べる。

最後の章では付録として、本研究と並行して開発したDEAのPythonによるオープンソースソフトウェアについて紹介する。

2 本研究において前提となる知識

2.1 データ包絡分析法 (DEA)

DEA は、線形計画法によって複数の尺度を効率値という一つの指標にまとめるノンパラメトリックな評価手法である。一般に DEA では入力に該当する項目を最小化して、出力に該当する項目を最大する。つまり、少ない入力でより多くの出力を得ることを、パフォーマンスが高いと評価する。この際、効率値を測る対象は DMU と呼ばれ、市、政府、銀行、大学、病院、会社などを含む事業体のことを示す。DEA において、入出力は多変量を扱うことが可能であるため、さまざまな項目を扱う事業体の場合にも効率値を算出することが出来る。

効率値を算出するためには、以下で説明する線形計画問題を解く必要がある。 $x_{i,j}$ を j 番の DMU に対する m 次元の入力の i 次元の値とし、 $y_{r,j}$ を j 番の DMU に対する s 次元の入力の r 次元の値とする。 n を全 DMU の数、 k を評価対象の DMU の番号とすると、入力指向の constant returns to scale (CRS) のフロンティアを持つ DEA 包絡モデルは式 (1) のように表すことができる。ここで、 $\theta(k)$ は効率値であり、 λ は最適化問題の決定変数である。

$$\begin{aligned} \min \quad & \theta(k), \\ \text{s.t.} \quad & \sum_{j=1}^n \lambda_j x_{i,j} \leq \theta(k) x_{i,k}, \quad i = 1, \dots, m \\ & \sum_{j=1}^n \lambda_j y_{r,j} \geq y_{r,k}, \quad r = 1, \dots, s \\ & \lambda_j \geq 0, \quad j = 1, \dots, n \end{aligned} \tag{1}$$

一方で、線形計画問題の双対問題として、各変数に対して重みを定義して定式化した乗数モデルも存在する。式 (2) がその定式化である。ここで、 μ 、 ν はそれぞれ出力乗数、入力乗数と呼ばれる決定変数である。これらモデルは同じ効率値を算出するが、モデルに組み込むことが出来る手法が異なるため、応用時の必要性に応じてどちらかのモデルが選択される。




図 10: 入力指向 DEA の概要図。赤丸がある非効率的 DMU の目標である仮想 DMU を示す。

$$\begin{aligned}
 \min \quad & \sum_{r=1}^s \mu_r y_{r,k}, \\
 \text{s.t.} \quad & \sum_{r=1}^s \mu_r y_{r,j} - \sum_{i=1}^m \nu_i x_{i,j} \leq 0, \quad j = 1, \dots, n \\
 & \sum_{i=1}^m \nu_i x_{i,k} = 1, \\
 & \mu_r \geq 0, \quad r = 1, \dots, s \\
 & \nu_i \geq 0, \quad i = 1, \dots, m
 \end{aligned} \tag{2}$$

以上によって算出された効率値をもとに、効率値が1の場合を効率的 DMU、それ以外を非効率的 DMU として扱う。ここで改善の対象となるのは非効率的 DMU である。また、図 10 に示すように、効率的 DMU は効率的フロンティアを構成し、このフロンティアを目標としてパフォーマンス改善を行う。

非効率的 DMU は入力指向の場合、入力値を割合的に削減することで効率的 DMU までパフォーマンスを改善することができる。この際、改善目標とする効率的 DMU

は仮想 DMU として、 λ の重みと効率的 DMU による線型結合で表現することができる。図 10 は、非効率的 DMU が仮想 DMU に至るための入力値の削減方法を示す。パフォーマンス改善のためには、入力値を削減して改善する入力指向と、出力を増加して改善する出力指向という手法があり、どのように改善を実現するかという観点で使い分けられる。出力指向包絡モデルの場合、モデルは式 (3) で定義される。

$$\begin{aligned}
& \max \quad \theta(k), \\
& \text{s.t.} \quad \sum_{j=1}^n \lambda_j x_{i,j} \leq x_{i,k}, \quad i = 1, \dots, m \\
& \quad \sum_{j=1}^n \lambda_j y_{r,j} \geq \theta(k) y_{r,k}, \quad r = 1, \dots, s \\
& \quad \lambda_j \geq 0, \quad j = 1, \dots, n
\end{aligned} \tag{3}$$

また、フロンティアは CRS や variable returns to scale (VRS) のように指定することができる。CRS は入力に対する出力の増加が一定なモデルであり、VRS は入力に対する出力の増加は変化するモデルである。図 11 はこの概要を示す。このように、VRS と CRS では目標とする DMU が異なる。ある非効率的 DMU を改善する場合、VRS の場合は DMU B まで入力値を削減すれば良いが、CRS の場合は DMU A まで改善する必要がある。これらも応用時の問題設定により、適切なフロンティアの設定が用いられる。

2.2 Context-dependent DEA

本研究では 1.3.1 章に説明した通り、改善の実現可能性を特に重要視する。それは、無理な空調機器の改善提案は、ユーザーの快適性を犠牲にする可能性につながり、また改善提案の納得性を下げてしまうからである。このような実現可能性に関する課題は DEA の分野でも取り扱われており、それは非効率的 DMU を効率的 DMU まで一度に改善することが難しい可能性があるということである。この問題を解決するために、Lim らは context-dependent DEA (CD-DEA) [56] による段階的な改善方法を提案した [57]。本研究で取り扱う改善経路の研究に関しては、そのほとんどがこの層化のために CD-DEA を前提とされている。そのためまずは CD-DEA について説明する。

CD-DEA はフロンティアを段階的に構成する手法である。すべての DMU の集合を $J^1 = \{DMU_j, j = 1, \dots, n\}$ とし、さらに $E^l = \{DMU_k \in J^l \mid \theta^*(l, k) = 1\}$ を用いて $J^{l+1} = J^l - E^l$ と表現する。ここで、 l と k をそれぞれ層と DMU を表すインデックスとして、 $\theta(l, k)$ は l 層 k 番の DMU の効率値とし、その最適値を $\theta^*(l, k)$ と




図 11: VRS と CRS の比較

する。また、 $j \in F(J^l)$ とは $DMU_j \in J^l$ を意味する。以上を用いて定式化される式 (4) は、入力指向の CRS のフロンティアを持つ包絡モデルである。

$$\begin{aligned}
& \min \quad \theta(l, k), \\
& \text{s.t.} \quad \sum_{j \in F(J^l)} \lambda_j x_{i,j} \leq \theta(l, k) x_{i,k}, \quad i = 1, \dots, m \\
& \quad \quad \sum_{j \in F(J^l)} \lambda_j y_{r,j} \geq y_{r,k}, \quad r = 1, \dots, s \\
& \quad \quad \lambda_j \geq 0, \quad j \in F(J^l)
\end{aligned} \tag{4}$$

ここで、とくに $l = 1$ のとき、式 (4) は典型的な入力指向 CRS 包絡モデルであり、式 (1) と一致する。 $l = 2$ のとき、第二段階のフロンティアは、最初に構成されたフロンティアの DMU を取り除いた集合に対して DEA を再度適用することで得ることができる。これを繰り返すと図 12 のように全 DMU をフロンティアの層に分けることができる。CD-DEA ではこのように層に分けられることにより、魅力度、発展度という指標を用いることができる。

$DMU_q \in E^{l_0}$, $l_0 \in \{1, \dots, L-1\}$ に対し、式 (5) の最適値である $H_q^*(d)$ は、 E^{l_0} 層からみた d 次の魅力度 (Attractiveness) と定義される。この魅力度は、 E^{l_0+d} 層か




図 12: 入力指向 CD-DEA の概要図

らみた DMU_q の相対的な魅力を示すものであり、魅力度が大きいとは、 DMU_q が評価の状況 E^{l_0+d} 層から離れていることを示す。

$$\begin{aligned}
 \min \quad & H_q(d), & d = 1, \dots, L-1 \\
 \text{s.t.} \quad & \sum_{j \in F(E^{l_0+d})} \lambda_j x_{i,j} \leq H_q(d) x_{i,q}, & i = 1, \dots, m \\
 & \sum_{j \in F(E^{l_0+d})} \lambda_j y_{r,j} \geq y_{r,q}, & r = 1, \dots, s \\
 & \lambda_j \geq 0, & j \in F(E^{l_0+d})
 \end{aligned} \tag{5}$$

$DMU_q \in E^{l_0}$, $l_0 \in \{2, \dots, L\}$ に対し、式 (6) の最適値である $G_q^*(g)$ を用いて、 $M_q^*(g) = G_q^*(g)^{-1}$ は、 E^{l_0} 層からみた g 次の発展度 (Progress) と定義される。この発展度は、 E^{l_0-g} 層からみた DMU_q の相対的な発展性を示すものであり、発展度が大きいとは魅力度と同様、 DMU_q が評価の状況 E^{l_0-g} 層から離れていることを示すため、発展性が高いと解釈される。

$$\begin{aligned}
\min \quad & G_q(g), & g = 1, \dots, l_0 - 1 \\
\text{s.t.} \quad & \sum_{j \in F(E^{l_0-g})} \lambda_j x_{i,j} \leq G_q(g) x_{i,q}, & i = 1, \dots, m \\
& \sum_{j \in F(E^{l_0-g})} \lambda_j y_{r,j} \geq y_{r,q}, & r = 1, \dots, s \\
& \lambda_j \geq 0, & j \in F(E^{l_0-g})
\end{aligned} \tag{6}$$

2.3 DEA における段階的な改善経路

CD-DEA の層化によって DMU はフロンティアの各層に分配され、層から層への改善を繰り返すことによって段階的な改善経路を作成することが、基本的な段階的な改善手法である。このように段階的に目標となる適切な DMU を選択するためには何らかの指標が必要であり、魅力度、発展度、非実現度合がまず用いられた [57]。この非実現度合は事前に設定した改善量に対する線形制約から外れた度合いを示す数値である。彼らはさらに、効率的 DMU の線型結合である仮想 DMU は実在する




図 13: 仮想 DMU と実在 DMU を用いた段階的な改善経路 [57]




図 14: 実在 DMU のみを用いた段階的な改善経路 [57]

データではないため、改善目標とすることの難しさを指摘した。データが実在しないということは、改善目標である仮想 DMU はデータの組み合わせとして実現することが不可能である可能性を含むからである。また仮想 DMU では入出力の値の他に詳細な情報が使えないため、改善の際に参考とすべき情報が不足するという観点もある。仮想 DMU ではなく実在 DMU のみを改善目標とする方法が提案されたのはこれら問題を避けるためであった。

改善経路に仮想 DMU と実在 DMU を用いる場合の経路は、図 13 のようになり、フロンティア上の点が利用可能なためスムーズな改善経路を実現できる。しかし先述の指摘のとおり、 E^3 層以降の段階的な改善は仮想 DMU を伴うため、改善の実現可能性を下げる可能性がある。このように仮想 DMU を用いて段階的に改善する方法は、さらに二段階の改善や勾配基準の改善手法も提案されている [58], [59]。

一方、すべて実在 DMU で改善経路を扱う場合は、図 14 のような経路になる。この場合は一つ一つの改善目標は実在の DMU であるため実現可能性が高いとされた。しかし、仮想 DMU を用いない場合は、実在する DMU のみしか用いることが出来




図 15: 類似 DMU 間での改善を前提とした段階的な改善経路 [60]

ずに改善目標の候補が制限されてしまう。図 14 から明らかなように、最初に削減した入力値を増やすような改善が含まれる場合もある。さらにこれは次に示される zigzagging 問題を引き起こす。

Park ら [60] は、この実在する DMU のみという制限が zigzagging 化と呼ばれる改善コストの増加問題を発生させると指摘した。これは入力指向においてたとえば、ある入力 A を減らして次層のフロンティアに改善したのち、次の改善においては入力 A を増やしてでも入力 B を減らす、というような改善経路である。具体例としては、図 13 は最初の改善では入力 1 を減らしているが、以降の改善では入力 1 は増えている。こういった改善が積み重なると、段階的な改善量の合計が、一度に第一フロンティアまで改善するために必要だった量を超えてしまい、改善のためのコストが増加してしまうということである。彼らはまた、既存の文献は改善に対するリソース分配の割り振りの一貫性について言及していないと指摘した。これはつまり、総コストだけでなく、様々な改善パターンが存在することによって、それを実行する側の対応が煩雑になることを懸念している。彼らはこれらの問題を解決するため、図 15 のように類似性の高い DMU 同士の範囲内で改善経路を考えるというアイデアを提案した。




図 16: CD-DEA と改善経路をクラス分類によって統合させた図 [60]

このような改善経路を実現するために、彼らは K-means によるクラスタリング手法を用いて似たような DMU 同士を分離することで、改善量のリソース分配を効率化して改善コストの増加を抑えた。具体的にはクロス効率性 [61], [62] を指標にクラス分類を行う際に、最終目標 DMU を第一層のフロンティア上の DMU としてクラスタの重心とした。図 16 が示すように、効率的 DMU の数はクラスタ数と一致し、そのクラス内で改善経路が構成される。彼らはこのようにして、CD-DEA とクロス効率性と段階的改善の全てをクラス分類によって関連付けた。

これらの先行文献は、実在の DMU のみを用いる改善経路の場合、改善候補が制限されることによる zigzagging 化を抑えること、改善方針の一貫性を保つことが重要であると示している。この文献が課題として残しているのは、データによっては層が多くなることで、フロンティアまでの改善を目的とした場合に多くの改善を実行しなければならないことである。これは一度の改善にかかる工数が大きい場合に問題となる。




図 17: 制約を満たす範囲内において層を越えることを前提とした段階的な改善経路 [63]

An ら [63] はさらにこれら既存文献について、各改善において実際に増やしたり減らすことのできる変数の量が制限されていることについて観点を欠いていると指摘した。既存文献は層から層へと段階的に改善するもので、その際の目標はもっとも近い、もしくは妥当な目標を選定することにより、一度にフロンティアまで改善するよりは実現可能性のある選択を取ることであった。しかしその際に改善可能な量として制約を置いて目標選択はしていなかったため、実現可能性を阻害する可能性が残されている。また、段階的な改善は全体としてみると無駄な段階を踏んでいる可能性もある。彼らは制約を導入して、その範囲内で最適な目標を選択することで、図 17 のように段階的ではあるが層をまたぐクロスレイヤーの考え方を導入した。これによって改善回数の課題に対応した。彼らは境界制約を用いたが、Lim ら [57] が導入した線形制約も選択に入るとした。これら制約の選択は、適用する先のデータによる部分もあり、議論の余地が残るとされている。

表 4: DEA の改善経路を段階的に行う既存手法のまとめ

参考文献	DMU	評価指標	制約	クロスレイヤー構造
Lim et al. [57]	実在 DMU	Attractiveness, progress and infeasibility	Joint linear constraints	なし
Park et al. [60]	実在 DMU	Same cluster	なし	なし
Ramón et al. [58]	仮想 DMU	Closest targets and local efficient frontier	なし	なし
Lozano et al. [59]	仮想 DMU	Gradient-based trajectories	なし	—
An et al. [63]	実在 DMU	Closest targets and weighted distance	Bounded-change constraints	あり

表 4 はこれらの改善経路に関する研究をまとめたものである。この表で、(—) は層の構造を取り入れていないことを意味する。実在する DMU のみを用いる手法を提案している [57], [60], [63] の適用分野は全て輸送業であり、残りの仮想 DMU を加味する文献は教育関係である。まとめとしては、DEA を応用する上で実現可能性に対処する場合、改善経路を段階的に捉えることが有効であり、より慎重に改善を捉える場合は、仮想 DMU ではなく実在する DMU を改善目標とすることが効果的であるということである。さらに、改善回数が増えることや改善コストの増加のデメリットを打ち消すには、類似性の高いグループ内での改善か、制約内で改善回数をカットする改善が有効である。

本論では空調運用に関する改善において改善量の制約を置くことが可能であるため、後者の制約内で改善回数をカットするという手法で、段階的な改善のデメリットを抑えメリットを反映させる方針を選択する。また、仮想 DMU ではなく実在の DMU のみを用いて目標選択を行う。これは、より詳細な情報を用いて改善対象と改善目標の比較を行うためであり、どのように改善するかをより具体的に考えるためである。以上によって、快適性を損なう可能性を減らし、かつユーザーとビルオーナーの納得性の高い改善目標を作成する。

2.4 DEA の結果を活用する分析

DEA は効率値や改善量、包絡モデルであれば参照集合、乗数モデルであれば入出力変数の重みなど、様々な結果を出力する。そのため、単に効率的な DMU や非効率的な DMU の効率値を見るだけではなく、その結果の解釈や活用も行われている。本論においては、DEA の結果から知見を抽出することによって、それを実際のエネルギーマネジメントに生かすことを目的としており、その実現のために DEA の結果の利活用の研究事例から有効な方法を探る。

DEA の結果の活用に関しては、その結果を別のデータによって関連付けることによって新たな知見を抽出する方法が提案されている。これは DEA の効率値によって効率的であれば 1、そうでなければ 0 というようにクラスを分け、その二値分類を解いたモデルを解釈することによって、新たな知見を得る方法である [64]。その研究の手法は、DEA の入出力に用いていないカテゴリデータやその他のデータを用いて分類モデルを解くことで、意思決定者に対してより有用な知見を抽出した。モデルには決定木を用いることで、図 18 のように分類を行う際のルールを明示的に取り出すことができる。この方法は、DEA の入出力に用いた値以外を使うことによって、新たな関連性を分析できる点にある。この手法の課題は、DMU の数が限られているとモデルの学習に必要なデータが不足することであるが、彼らはブートストラップ法によってそれに対処した [65]。




図 18: 決定木による DEA のスコア分類のためのルール [64]




図 19: 二値分類モデルの適用種類と全体像 [66]

先行文献では指摘されていないが、この手法のもう一つの課題はモデルの精度であると考えられる。DMU 以外の値という制約がある中で十分高い精度で予測することが難しい場合があることと、精度に対する十分性を意思決定者がどのように受け止めるかである。この精度に対しては様々なモデルが検証された [66]。彼らは、図 19 のようにいくつかのモデルを適用してその精度を比較したが、単純な決定木はアンサンブル学習モデルから 10%ほど落ちる精度であった。しかしながら、アンサンブル学習モデルは決定木のようにルールを抽出することが難しく、重要度という指標を提供できるのみである。そのため、高精度を求めるほど説明性が減少してしまう。また、これらは文献では触れられていないが、この手法では 0.98 のように 1 に近い効率性の DMU であっても、0.50 程度の非効率 DMU と同等のクラスとして扱われる。二値分類ではその分類の境界に課題が残る。




図 20: クロス効率値に基づく階層的クラス分類 [67]

DEA の結果の活用は効率値に関する分析も存在する。効率値をクロス効率値で測定して順位付けを行い、そのスコアに対してクラスタリングを行うことで、図 20 のように DMU をクロス効率値によって似たグループに分類することができる [67]。これによって、もっともスコアが低い集団を特定することができ、その集団に対し

での施策を最優先すべきという判断を下すことができる。またこの場合、同じ階層に存在するもっとも効率値の高い DMU をその集団の改善目標とする、というような考え方も示されていた。この場合、階層的クラスタリング手法が用いられるが、単に効率値の低いターゲットをグループ化するならば階層的である必要はない。しかしのちの分析によって、これらを階層的に管理する利点が述べられた [68]。彼らによると、既存の DEA は非効率的な DMU に対する改善目標には課題があり、主問題は効率的 DMU の線型結合である改善目標は、常に理解しやすいものではないという。また、理論的には改善目標まで入出力を改善すればフロンティアまで到達できるが、それは現実的には難しい場合もあると指摘している。この考えは、改善経路の手法と同じ課題認識を持っている。彼らは、まず同じクラス内でもっとも効率値の高い DMU を目標とし、それを達成した後に上位のクラスに進み同じことを繰り返していくことで、段階的な改善を行うことができると提案した。このためには階層的な結果が必要である。これら文献の共通の課題意識は、改善の実現可能性を高めるには、似たような DMU 同士であることや段階的な改善が必要であることである。

3 DEAによる実現可能性を考慮した空調運用の改善

3.1 本手法の特徴と応用先

本手法は、空調運用方法を改善する目的で、履歴データを DEA の枠組みで扱うための DMU の設定方法に独自性がある。これは 3.2 章で説明する。さらに段階的な改善は、既存手法では各改善による状況変化を加味しない問題設定であったが、本論では一度の改善が行われるとデータが更新されるという状況設定である。この問題設定は既存の問題設定を拡張したものである。

このような問題設定のため、クロスレイヤー構造を取り入れつつ、第一フロンティアになるべく近い DMU を目指すという方針をとることが有効である。そのため、クロスレイヤー構造に対して発展度、魅力度の指標を用いる意味が発生する。この手法の組み合わせは今までにないが、提案手法は単なる組み合わせではない。なぜなら、一層毎の段階的な改善の場合は、魅力度と発展度は前後の層に対して算出すればよかったが、層を越えるクロスレイヤー構造の場合は、どのように各指標値を算出するかという問題があるためである。本研究ではその算出方法を工夫することで、クロスレイヤーの場合にも適用させたという点が新規性である。表 4 のうち本手法は、実在 DMU を用いること、評価指標に発展度と魅力度を用いること、クロスレイヤー構造を取り入れることを必要としているが、制約については選択の余地がある。その制約は、固定的な制約か変動的な制約であり、これら二つの比較も本論で行う。また制約については、同質の変数を入力に持つ DEA の場合、線形制約の条件を総和で簡易化できるという点も本論の特徴である。これらは 3.3 章で説明する。さらに結果の解釈について、本研究では単なる効率値や経路の比較ではなく、実際に改善施策を実施するための分析方法も加えており、これについては最後に 3.4 で紹介する。

この提案手法の応用は空調運用データのみには制限されるものではない。この手法が効果を発揮するのは、現実的に可能な範囲で改善したい場合であり、かつ改善を繰り返すがその度にデータが更新される状況である。既存文献の問題設定では改善経路を構築する際、ある DMU に対して二度の改善を行う場合はその間に他の DMU は変化しないことを前提としている。しかし改善の間に時間が空く場合、その間に全体の状況が変化する可能性がある。改善計画時点でフロンティアまでの経路を考えるのではなく、一度の改善でフロンティアまで近づけつつ、次の改善はデータが更新されてから算出する方が、最新の情報を反映した意思決定が可能になる。本手法はこのような状況でこの利点を得たい場合、どのような分野でも適用できる。ただし改善時の制約を設計するためには、適用先の分野の情報を必要とする。

3.2 空調運用データの扱い方

本章は DEA による空調運用改善の方法を提案する。ここではまず、DEA において空調運用改善を行う場合、空調運用履歴をどのように DMU として構成するかという部分が重要になる。1.3.2 章によると、オフィスにおける従業員の行動はオンオフなどの運用データに反映され、その行動の結果、より少ないエネルギーで運用されている日が存在するということであった。従業員の行動は、運用時間として VRF システムの室内機の運用履歴に蓄積されるため、日毎に各室内機の総運用時間を見ることが、より効率的に運用されていた日を特定することが期待できる。

さらに、1.3.1 章でまとめたように、改善が実現可能で受け入れやすいことが重要である。なぜなら空調システムの使用を減らすことはユーザーの快適性に悪影響を及ぼす可能性があるからである。各室内機を別々に扱う場合は個別最適化となり、部分的には実現可能だが同時に実現することが難しい運用となる。各部屋の滞在者数は変わっても、在籍者の総人数は大きく変動しないため、必要な熱処理量は個別ではなく同時に扱うことが、過剰な目標設定を避けるためには必要である。以上より、室内機の運用時間は多次元のインプットとして扱う。

以上の観点から、本研究では空調機器の日毎の運用時間として、各室内機の日毎の総運用時間を一つのデータ点として扱うことで、各点を DMU として定義する。DEA の入力には各室内機の総運用時間となり、入力次元は対象の VRF システムが持つ室内機総数と同様であり、図 21 の場合、DEA では 3 次元の入力として扱われる。今回出力に該当する項目はないため $C = 1$ という定数を用いる。本研究の目的から考えると、入力値を減らすことで運用を改善するため、入力指向の DEA を CRS フ




図 21: DEA における VRF システムの表現

表 5: DMU としての空調運用データのサンプル

DMU	日	室内機 A	室内機 B	室内機 C
1	7-1	854	611	716
2	7-2	828	690	688
3	7-5	865	903	565




図 22: 本研究が取り扱う提案手法の改善経路のイメージ

ロンティアを仮定して用いることが適切である。出力一定では CRS は VRS と区別されないため、フロンティアの種類はどちらでも結果は変わらない。

表 5 はより具体的な理解の補助のためのサンプルデータとして、例えば図 8 の室内機を 3 つ持つシステム 2 の運用履歴を示す。例えば、7 月 5 日の室内機の運用時間は DMU_3 として表現され、その日に室内機 A は 865 分、室内機 B は 903 分、室内機 C は 565 分間の運用をしていたことを示す。また本研究では、 $x_{i,q}$ がある日（識別子 q ）の室内機 i の総運用時間を示すため、 DMU_3 である 7 月 5 日は、 $x_{1,3} = 865$ 、 $x_{2,3} = 903$ と $x_{3,3} = 565$ と表現される。

本論では改善経路を段階的に扱うために CD-DEA により層化するが、段階的な改善ではなく制約内で最も効果的な改善を行う。また、実在しない理想的な運用日を目標とすることは、ユーザーとしてはそのような運用はしたことがないと受けとられるが、実際に運用していた日を目標とすることは、ユーザー自身が制御した記録であるため改善対象として納得性が高い。そのため実在 DMU のみを対象とした改善経路を前提とする。図 22 は通常の DEA と段階的な DEA の改善と、提案手法と




図 23: 本研究手順のフローチャート

して層を超える改善を示す。これは、 E^1 を目標とした DMU_K からの改善経路を示したものである。層を超える場合は、制約を満たすことと、制約内の最も効果的な目標であることの二点が重要になる。本論における制約は改善量の限界値を定めることであり、効果的な目標であることは、最終目標層に向かいやすく最大限効果的な改善量を担保できることである。

本研究のフローチャートは、まず必要となるデータを収集して、次にそのデータを CD-DEA により層化する。その後、最終目標とする層と改善限界量を定め、制約内の効果的な改善目標を各日に対して特定する。最後に、その結果を用いて空調運用を改善する提案を行う。図 23 は上記をまとめたものである。他の VRF システムに適用する場合は、この手続きを同様にを行うことで対応することができる。

3.3 実現可能性の高い改善日の特定

まず、CD-DEA を適用して全ての DMU を各層に分ける。このとき、全ての DMU を表す集合は J^1 であり、 $\bigcup_{1 \leq l \leq L} E^l$ と同等である。以降、分かりやすさのために $a, b \in \mathbb{N}$ に対して $E^{[a,b]} = \bigcup_{a \leq l \leq b} E^l$ と表す。また同様に半开区間の場合も、 $E^{(a,b]} = \bigcup_{a < l \leq b} E^l$ や $E^{[a,b)} = \bigcup_{a \leq l < b} E^l$ のように表記する。ある DMU に対して改善目標を考えると、次層の DMU を目標として改善を繰り返すのではなく、最終目標の層を決めてから、一度の改善でできる限り効果的な改善を行うことを考える。この際、

最終目標とする層は $T \in \{1, \dots, L-1\}$ を用いて E^T と表す。基本的には $T = 1$ とすると存在する DMU 全体におけるフロンティアを目標とすることになるが、その層が外れ値によって影響を受けて歪んでいることが明らかな場合、もしくは実用上高すぎる目標値であることが明らかな場合、第二層を最終目標とすることも選択できる。このとき、改善対象となる DMU は目標層より下にある DMU であり、 $E^{(T,L]}$ と表す。この改善対象となる DMU の集合を可視化したものが図 24 の左の図である。最終目標層を決定し、改善対象となる集合を明確化した後は、この改善対象となる集合に属する全ての DMU に対して改善候補を特定する必要がある。各 DMU に対する改善候補を特定する方法は全て同等であるため、以降はある DMU_q に対して改善候補を選定する方法について説明する。

次に、改善対象集合のある与えられた $DMU_q \in E^{(T,L]}$ に対して、改善目標となる DMU_{q^*} を特定するための候補の集合を定義する。 DMU_q に対する改善候補目標は、 DMU_q が属している層 l_0 を用いて、その層より上にある目標層までの DMU 全てであり、 $E^{[T,l_0)}$ と表す。 DMU_{q^*} は DMU_q の改善目標であり、 q^* は $F(E^{[T,l_0)})$ から選ばれた添字である。ここで $j \in F(J^l)$ とは $DMU_j \in J^l$ を意味する。この集合から実現性の高い最も効果的な DMU を選択する。この改善候補となる DMU の集合を可視化したものが図 24 の右の図である。この候補は実現可能性を高めるための改善量による制約を課していないので不十分である。さらに、目標を現実的な値に限定するため、実現可能性の低い DMU を除外して改善候補の集合を作成する。改善先の選択には制約を課している。本稿の目的は、より少ない稼働時間で運転できる日を探すことであるため、改善先では総入力値がより少なくなるようにする必要がある。加えて、一度に可能な改善量を制限するため、総運転時間の合計値の削減量




図 24: 改善対象の集合 $E^{(T,L]}$ と、ある DMU_K の改善候補の集合 $E^{[T,l_0)}$

が指定値 C 以下であるという必要がある。このために、 DMU_q の改善候補 DMU_k に次のような制約を課す。この制約は合計値に関するものなので、各変数の単位が異なる場合は意味をなさない。しかし今回のように全て同質のデータである場合は問題がない。

$$\sum_{1 \leq i \leq m} (x_{i,q} - x_{i,k}) > 0 \quad (7)$$

$$\sum_{1 \leq i \leq m} (x_{i,q} - x_{i,k}) \leq C \quad (8)$$

J_q^1 が式 (7) と 式 (8) を DMU_q に対して満たす集合とすると、改善候補集合は $E^{(T,l_0)} \cap J_q^1$ と表現することができる。これは無茶な改良を抑制する実現可能性の制約となる。この C の制約値はビジネスオーナーによって決められるもので、ビルオーナーと従業員との合意が必要なものである。たとえば空調機器の使用時間を改めるが、合計 3 時間を超えない範囲での改善から試してみる、などである。より柔軟に状況を扱うために、総運転時間の制約ではなく各室内機に対する制約を置くことも可能であり、これらはユーザーによって必要とされる状況が異なる。また、コントロール不可能な入力値として扱うことで、特定の室内機に対しては改善を行わないで評価することも DEA の枠組みで可能であり、この部分は幅広い状況に対応することができる。

式 (7) と 式 (8) は表 4 の Joint linear constraints に該当する制約であり、どの DMU に対しても同様の制約である。一方、Bounded-change constraints に該当するのが次の式 (9) である。

$$\sum_{1 \leq i \leq m} (x_{i,q} - x_{i,k}) \leq \alpha \sum_{1 \leq i \leq m} x_{i,q} \quad (9)$$

この場合、重み α は $0 < \alpha < 1$ を満たす値として設定する。このようにすると、各 DMU における入力値に応じた制約になるため、改善難易度のような概念を組み込むことができる。ただし、どちらを選択するかは、改善する際の方針による。例えば、無駄に使用している可能性があるならどこでも削減する場合は固定的な制約が必要であるし、より改善を実行しやすいように長い使用時間を優先して改善したい場合は変動的な制約を入れる必要がある。そのため、これらは実行する際の目的に応じて使い分けるものである。また、式 (8) と 式 (9) のように総和をとった値による制約でなく、各変数毎に対する制約や、各変数に重みをかけた総和による制約でも可能である。各変数毎に優先度がある場合はこのような拡張も可能である。




図 25: DMU_K に対する改善量の制約を満たす領域

図 25 は DMU_K に対する式 (7) と式 (8) によって制限された領域を示す。たとえば、 DMU_I は DMU_K より上位の層にあるが、式 (7) の制約を満たさないため、改善候補の集合には含まれない。同様に、 DMU_B は DMU_K より上位の層にあるが、式 (8) の制約を満たさないため、改善候補の集合からは除外される。この領域の大きさは改善対象とする DMU によらないが、式 (9) の場合は、対象 DMU の層が最終目標の層に近づくにつれて領域を小さくする、という動的な制約となる。これはエネルギー使用量を削減するという改善が、少ない運用時間になるにつれて難しくなる、という仮定を反映する。本論においては改善対象の DMU によらない式 (7) と式 (8) の制約を基本とするが、一部に式 (9) との比較した結果も考察する。

最後に、全ての改善候補 DMU の集合 $E^{[T, l_0]} \cap J_q^1$ から改善目標を選定する。ここでは、何らかの指標をもとに、 DMU_q に対する最も効果的な目標 DMU_{q^*} を選択する必要がある。改善対象の DMU と改善目標のユークリッド距離が最も大きいなどの指標も考えられるが、本研究では発展度と魅力度を用いる。発展度と魅力度は 2.2 章で導入した通り、 $DMU_q \in E^{l_0}, l_0 \in \{1, \dots, L-1\}$ に対し、 $H_q^*(d)$ は層 E^{l_0} から見た d 次の魅力度として定義され、また、 $DMU_q \in E^{l_0}, l_0 \in \{2, \dots, L\}$ に対し、 $M_q^*(g) = G_q^*(g)^{-1}$ は、 E^{l_0} 層からみた g 次の発展度と定義される。

これら指標を用いる理由は、提案手法が用いる改善目標の選択基準が、最終目標層には近いほど良いが制約を満たす範囲内の DMU である、ということに起因する。つまり、あくまで目標は第一フロンティアである目標層に近い DMU であることなので、層と DMU の間で近さを測る必要がある。そのため、発展度を最終目標層から

みた改善候補の DMU に対して測る必要があり、発展度を用いることから魅力度との割合で基準を作成する手法を用いた。改善目標は実在の DMU に制限するが、仮想 DMU を生成するフロンティアとの近さを指標にするのは上記の理由からである。

ここでは、 $DMU_K \in E^{[T, l_0]} \cap J_q^1$ に対し、魅力度を $H_k^*(l_0 - l_k)$ 、発展度を $M_k^*(l_k - T)$ とする。魅力度はある改善候補 DMU_K の効率性を DMU_q が属する層の DMU から測った値であり、発展度は T 層からある改善候補 DMU_K の効率性を測った値である。この二つの値を用いて DMU_q の改善目標である DMU_{q^*} を以下の式から得る。本研究では実現性については制約を満たすか満たさないかという条件で扱い、制約を満たす候補に対して発展度と魅力度の二つの値で評価する。これら指標は割合の値であるので、線型結合ではなく割合で扱う方が自然である。

$$q^* = \arg \max_{k \in F(E^{[T, l_0]} \cap J_q^1)} \frac{H_k^*(l_0 - l_k)}{M_k^*(l_k - T)} \quad (10)$$

以上全てのフローをまとめると、次のアルゴリズムとして示すことができる。

Algorithm 全ての改善対象となる DMU に対して改善目標を選定する

CD-DEA を適用して全ての DMU を各層に分配する

最終目標とする層として T を $T \in \{1, \dots, L-1\}$ から決める

for $l_0 \in \{T+1, \dots, L\}$ do

 for $DMU_j \in E^{l_0}$ do

 for $DMU_k \in E^{[T, l_0]} \cap J_j^1$ do

 魅力度と発展度として $H_k^*(l_0 - l_k)$ と $M_k^*(l_k - T)$ を算出する

 end for

DMU_j の改善対象 DMU として DMU_{j^*} を式 (10) から決定する

 end for

end for

より具体的な改善目標の選定手法の説明のために、例えば図 25 において改善候補の一つである DMU_E の指標を測る場合を考える。まず、改善対象である DMU_K は 4 層に属するため、 $l_0 = 4$ であり、 DMU_E は 2 層に属している。この場合、 DMU_E の指標値は $H_E^*(4-2)/M_E^*(2-1)$ である。このように候補全てに対して指標値を算出して、もっとも高い値をもつ候補を改善目標として選択する。

2.3 章の表 4 によると、魅力度と発展度を評価指標にして、クロスレイヤーの改善経路を用いる手法は新規の組み合わせである。この手法の優位性は、最終目標層に対して効果的な改善となるように目標選択ができる点と、層を跨ぐ改善によって

改善対象日と改善目標日の対応と差分

	改善対象日	改善候補日	入力1改善量	入力2改善量
DMU 1	7/15	8/1	100	120
DMU 2	8/12	8/19	50	180
...	...	...	...	...
DMU N	7/5	7/18	150	10




図 26: クラスター分析による結果活用方法のイメージ

zigzagging 化を抑制して改善コストの増加を抑えることができる点である。また、実現可能性については制約条件を課すことでより妥当な判断をすることができる。この手法は、一度の改善で第一フロンティアまで改善することが現実的ではない、もしくは必ずしも要求されない状況に対して有効であり、可能な限り第一フロンティアに近い実在する DMU を目指すことで効果的な改善を実現できる。既存文献と異なる点は、第一フロンティアに至ることは保証しないという点である。そのため、実在する DMU のみを目標としながらも、発展度という層に対する指標を用いる意味が発生した。

この手法の難しい点は適切な制約を課すことである。制約が強すぎると改善できる候補が見つからなくなってしまうたり、少しの改善しか期待できなくなってしまう。この研究では、たとえば改善候補がある日に対して見つからない場合も起きうるが、この場合その日は特異な日であるので改善の必要がないとも判断できる。

3.4 結果を用いたエネルギーマネジメント

DEA の結果を活用してどのようにエネルギーマネジメント施策につなげるか、という部分は応用上非常に重要になる。多くの DEA の応用文献では、結果を用いて改善する手段まで提案され実行されることは少なく、エネルギーマネジメント領域での応用も同様である。ここでは、DEA の結果をエネルギー削減施策につなげる方

法を提案する。

3.3 章の手法は、改善対象となる日すべてに対して改善目標を提供する。この結果からわかるのは、改善対象である日が改善目標に至るまで、どの室内機の運転をどのくらい減らすことが必要か、ということである。本論では仮想 DMU ではなく実際の DMU を改善目標にしているため、各日については総運転時間ではなく時刻別の運転時間を比較するなど、より詳細な比較が可能である。この比較の目的は、ユーザーが無駄に用いていた可能性のある空調機器の使用に気づくことである。この比較の方法では、対象となる日全てが比較の候補であるため、どの DMU から比較分析を行うべきか考える必要がある。またこれらは点の情報であるので全体像を掴むことは難しい。例えば、全室内機の運用時間を満遍なく削減するような改善が多いのか、特定の室内機を大きく削減する改善が多いのか、ということは DEA の結果のみからでは把握することが難しい。ここで課題となるのは、全ての運用日に対してそれぞれの比較をして分析するという方法では、分析するための時間が非常に多くかかるということである。また、全体像の把握や実際の省エネ施策に落とし込むための知見を得ることの難しさが残る。2.4 章では様々な DEA の結果の応用をまとめたが、その多くは結果から何らかのルールや情報を抽出することであった。本論でもそれらアプローチのように、クラスター分析によって必要な情報や知見を抽出する。

本論では、改善に伴う削減量に焦点を当て、図 26 のように DEA の結果を分類する。これによって、対象の空調システムの運用にはどういった種類の改善方法が、どのくらいの量存在するのかを理解することができる。例えば改善パターン A は、室内機 A を多く室内機 B を少し改善する方法のグループであり、全体の DMU の半分以上を含むとなると、ユーザーやオーナーが注意すべきはこの種類の改善方針であると捉えることができる。また、全ての日に対して詳細な時刻毎の比較を行わずとも、各パターンの代表的な一つの日に対して見ることで、おおよその傾向を掴むことが可能になる。これらを用いると、ユーザーやビルオーナーに対し、どの室内機のどの時間帯の運用により注意を払うべきか、という示唆を与えることが可能になる。全てを隈無く検証して改善するのではなく、現状より少しでもよい状態を目指すという方針によって、これら情報をもとにエネルギー削減の取り組みを行う。

このような結果活用を実現するためには、DEA の改善量をもとにクラスター分類を行うことが必要になる。DEA において、スラックを基準にしたモデル [69] の場合では改善量は比率ではないが、通常モデルは改善量は比率によって算出される。しかし本論では改善候補は観測上の DMU から選択されるため、比率による入力値の削減ではない。そのため各入力値をどのくらい削減すれば改善できるかというの

は多様な種類が存在する。この場合、改善方法を解釈してその結果を有効活用するために、クラス分類を行うことは効果的である。本論では K-means 法によって入力値の削減量を分類することで、全体としてどのような改善量の組み合わせが存在していたのかを大まかに分類する。K-means 法においては、クラスター数を指定する必要があるため、その基準が必要となる。本論では Davies-Bouldin index (DB インデックス) を用いて、適切なクラスター数を特定する [70]。また、全ての改善対象となる DMU とその目標となる DMU の差分は、その分布を見ることで全体の傾向を明らかにすることもできる。この比較の目的は、クラス分類の各視点からの考察ではなく、全改善に関してどの室内機のどの時刻に差分があるかを把握することである。これら二つの観点を持つことによって、より効果的なエネルギー削減施策を提案することができる。

4 ケーススタディ

4.1 実行手順とデータ

このケーススタディでは、3章の手法を実際のビルに適用することでその有用性の確認を行う。本章では、空調機器の運転履歴データの説明や適用先の部屋の情報、省エネ施策を実行するための集中管理コントローラーの説明を含む。空調機器の運用履歴データはまず冷房期間を通して取得した。ここから提案手法を適用して、改善すべき運用の日とその目標とすべき運用の日を特定する。最後に、クラス分類と差分の統計量を分析することで、省エネ施策のために有効な知見を抽出し、それをもとに実際に実施した省エネ施策を記載する。

本研究が対象としたのは日本にあるオフィスビルであり、冷房期間を 2021/07/01 から 2021/08/31 としてデータを取得した。このビルは2階建てであり、基本業務時間は9時から20時である。ターゲットとしたのは室内機 A、B、C を含むシステム 1 であり、そのシステムが導入されているのは2階のある一室である。図 27 はその部屋と空調システムのレイアウトを示す。このオフィスは 80 名の従業員が在籍し、平均約 10 名ほどが部屋 1、2、3 で業務を行う。対象システムは3つの室内機と一つの室外機から構成される VRF システムである。この機器の室外機の冷凍能力は 28 kW、室内機の冷凍能力はそれぞれ室内機 A が 11.2 kW、B が 4.5 kW、C が 3.6 kW である。また室外機はインバーターを導入しているので、熱負荷に応じて能力制御が行われる。




図 27: 適用する先の空調構成と部屋割




図 28: 室内機 A の 8/2 と 8/19 における時刻別の運用時間の違い

この環境では、複数の室内機で構成される VRF システムに対し、各室内機の運転データはクラウドシステムを経由して取得することができる。これによって、各時刻に何分運用していたのか、という粒度のデータまでを取得することができる。この運用時間というのは、室外機が能力を出して冷媒を室内機へ届けていた時間ではなく、室内機のリモコンのスイッチがオンであった時間である。これはユーザーがどのくらいの時間、指定の温度に空調制御されていることを期待したいか、ということを示す。

例えば、ある室内機の運転データは図 28 のように比較することができる。この図は 8/2 と 8/19 における室内機 A の運用時間を示す。この二つの日を比較することによって、図 28 は 7 時前と 19 時以降の運用時間に大きな違いがあることがわかる。つまり、このように日毎の違いと、その時刻毎の違いまで比べることができれば、削減できそうな運用をしていた時間や使い方があったかどうか判断できる可能性がある。

図 29 は集中管理コントローラーと空調機器の関係を示す。この集中管理コントローラーは BMS への連携を可能にするために、building automation and control networking protocol (BACnet) のためのインターフェースを提供することができる。この BACnet のサーバーゲートウェイオプションで、この集中管理コントローラーは BMS インテグレーターを提供し、VRF システムの室内機と室外機の運用をモニタリングしたり、オンオフを制御することができる。それぞれの室内機は各リモートコントローラーに接続されており、それらはオンオフ、室温、風向を設定し制御




図 29: 集中管理コントローラーと VRF システムの関係図

表 6: 各室内機の日毎の総運転時間の統計量

室内機	最小値	最大値	平均値	標準偏差
A	778	968	872	41
B	611	931	752	82
C	482	913	744	85

することができる。集中管理コントローラーはこの各リモコンと同様の制御を行うことができ、さらに特定の時刻に室温設定やオンオフ制御を起動させることができる。本章において、自動的な制御設定が示すのは、この集中管理コントローラーに設定することを意味する。このようなコントローラーは機能的に操作できることは限られるが、導入コストが比較的安いため、中小規模の物件で空調機器全般をコントロールするために用いられることが多い。

まずデータの前処理として、明らかに通常と異なると判断できるデータは前処理の段階で除き、通常用途の運用データを扱うことで外れ値の影響を抑えた。このケーススタディの場合、室内機がほとんど使われない日を除いており、その際に四分位範囲の 1.5 倍を上下限值として用いた。この閾値は分布による統計処理でも建物オーナーと確認が取れる値でも良い。表 6 によると、室内機 B や室内機 C が様々な運用

時間の幅を示すのに対し、室内機 A は最も長い時間運用している。特に室内機 C については、最も短い運用時間の日は最長の日の約半分の時間である。表 7 は全ての DMU を表し、図 30、図 31、図 32 は運用時間の分布を示す。図 33、図 34、図 35 は日毎の総運用時間の冷房期間にわたる分布である。これらの統計量と分布から、各室内機の運用時間は 80 分ほどなら削減することは難しくないと判断し、本手法の固定的な制約について C を 240 として扱うことにした。もう一方の変動的な制約については、 $\alpha = 0.076$ と設定した。これは、表 6 の平均値に対して、室内機の総和に α をかけて 240 となるように算出したものである。これは、状況に応じて制約値は変わるが、平均的な値としては固定的な制約と同レベルに揃えることで、比較を行いやすくするためである。




図 30: 室内機 A の冷房期間における時刻別運用時間日数のヒストグラム




図 31: 室内機 B の冷房期間における時刻別運用時間日数のヒストグラム




図 32: 室内機 C の冷房期間における時刻別運用時間日数のヒストグラム




図 33: 室内機 A の冷房期間における日毎の総運用時間の分布




図 34: 室内機 B の冷房期間における日毎の総運用時間の分布




図 35: 室内機 C の冷房期間における日毎の総運用時間の分布

表 7: 各室内機の冷房期間における日毎の総運用時間

DMU	日付	室内機 A	室内機 B	室内機 C
1	7-1	854	611	716
2	7-2	828	690	688
3	7-5	865	903	565
4	7-6	830	727	793
5	7-8	868	765	482
6	7-9	968	611	757
7	7-12	869	814	732
8	7-13	845	678	729
9	7-14	868	656	716
10	7-19	862	733	750
11	7-20	862	650	765
12	7-21	873	802	761
13	7-24	825	666	785
14	7-26	936	819	818
15	7-27	873	662	688
16	7-29	852	812	745
17	8-2	927	873	699
18	8-3	868	778	786
19	8-4	865	811	761
20	8-5	831	931	821
21	8-6	940	821	808
22	8-17	905	778	829
23	8-19	778	648	590
24	8-20	947	736	913
25	8-23	859	798	807
26	8-24	869	733	755
27	8-26	829	818	777
28	8-27	915	726	853
29	8-30	866	766	716
30	8-31	899	759	719

4.2 適用結果

表 8: 全 DMU に対する改善経路と必要な改善量（式（8）の場合）

DMU	改善目標								室内機の改善量			合計
	E^8	E^7	E^6	E^5	E^4	E^3	E^2	E^1	A	B	C	
13	7-26	—	—	—	—	8-26			107	1	41	149
21		8-17	—	—	—	—	7-24		80	112	44	236
20		8-06	—	—	—	—	7-5		75	-82	243	236
23			8-20	—	—	8-26			118	-82	136	172
17			8-3	—	—	—	7-24		43	112	1	156
11			7-21	—	—	—	7-24		48	136	-24	160
25				8-24	—	—	—	7-1	15	122	39	176
24				8-23	—	—	7-24		34	132	22	188
18				8-4	—	—	7-24		40	145	-24	161
29					8-31	—	—	7-1	45	148	3	196
27					8-27	—	7-24		90	60	68	218
19					8-5	8-26			2	113	44	159
15					7-29	—	—	7-1	-2	201	29	228
9					7-19	—	—	7-8	-6	-32	268	230
6					7-12	—	—	7-1	15	203	16	234
28						8-30	—	7-8	-2	1	234	233
26						8-26	7-24		4	152	-8	148
16						8-2	7-24		102	207	-86	223
7						7-13	—	8-19	67	30	139	236
4						7-6	—	7-8	-38	-38	311	235
14							7-27	8-19	95	14	98	207
12							7-24	7-8	-43	-99	303	161
10							7-20	7-8	-6	-115	283	162
8							7-14	8-19	90	8	126	224
3							7-5	7-8	-3	138	83	218
2							7-2	8-19	50	42	98	190
1								7-1	-	-	-	-
5								7-8	-	-	-	-
23								8-19	-	-	-	-

表 9: 全 DMU に対する改善経路と必要な改善量 (式 (9) の場合)

DMU	改善目標								室内機の改善量			合計
	E^8	E^7	E^6	E^5	E^4	E^3	E^2	E^1	A	B	C	
13	7-26	—	—	—	—	8-26			107	1	41	149
21		8-17	—	—	—	—	7-5		40	-125	264	179
20		8-06	—	—	—	—	8-26		111	3	31	145
23			8-20	—	—	8-26			118	-82	136	172
17			8-3	—	—	—	7-24		43	112	1	156
11			7-21	—	—	—	7-24		48	136	-24	160
25				8-24	—	—	—	7-1	15	122	39	176
24				8-23	—	—	7-20		-3	148	42	187
18				8-4	—	—	7-24		40	145	-24	161
29					8-31	—	7-24		74	93	-66	101
27					8-27	—	7-5		50	-177	288	161
19					8-5	8-26			2	113	44	159
15					7-29	—	7-24		27	146	-40	133
9					7-19	—	—	7-1	8	122	34	164
6					7-12	—	7-24		44	148	-53	139
28						8-30	—	7-1	12	155	0	167
26						8-26	7-24		4	152	-8	148
16						8-2	7-5		62	-30	134	166
7						7-13	—	7-8	-23	-87	247	137
4						7-6	—	7-1	-24	116	77	169
14							7-27	7-8	5	-103	206	108
12							7-24	7-8	-43	-99	303	161
10							7-20	7-8	-6	-115	283	162
8							7-14	7-8	0	-109	234	125
3							7-5	7-1	11	292	-151	152
2							7-2	7-8	-40	-75	206	91
1								7-1	-	-	-	-
5								7-8	-	-	-	-
23								8-19	-	-	-	-

4.2.1 全 DMU の改善経路とクラス分類結果

全ての日は CD-DEA によって 8 層のフロンティアに分けられた。 E^1 層は最初に抽出された層で、本データの中でもっとも少ない運用時間によって構成されるため、最良の運用をしていた可能性がある日である。次に E^2 層から E^8 層は順に抽出され、 E^8 層は空調機器の運用がもっとも長かった日の層である。表 8 は固定的な制約の下、全ての改善対象となる DMU の集合 $DMU_j \in \bigcup_{T < l \leq L} E^l$ に対する目標 DMU_{j^*} と、その改善を実行するために必要な改善量を取りまとめたものである。 DMU_1 、 DMU_5 と DMU_{23} は最終目標層である E^1 層に属するため改善の余地はないと判断される。(−) は記載されている部分の層を飛び越えて目標選択されていることを示す。たとえば 13 番目の DMU である 7/26 は 8 層に属している。この場合、制約の範囲内では 3 層の 8/26 まで改善することができると判断されたということである。この改善には室内機 A に対して 107 分、室内機 B に対して 1 分、室内機 C に対して 41 分の運用時間を削減し、合計 149 分の運用時間を削減すれば良い。20 番目の DMU の室内機 B のように、マイナス量の改善が発生することがあるが、これは該当する室内機の運用時間を増加させてでも、他の室内機の削減を優先すれば総合的に運用時間を減らせることを示している。表上の全ての日を改善したと仮定すると、その運転時間の削減は全使用量の 7.5% にものぼる。仮に熱負荷が一定であるとする、電力使用量も同様に 7.5% ほど削減できると見積もることができる。さらに、室内機 D、E、F を含むシステム 2 では同様の手法を適用することで 4% ほどの削減が期待できることがわかった。

表 9 はシステム 1 に対して、変動的な制約の下、つまり使用時間が多いほど改善量を多く、少ないほど少ない改善量のみを許可するモデルの場合の結果である。こちらの場合、使用時間が長い際には表 8 と比較しても差は少ないが、短くなるほど改善量が抑えられていることがわかる。また、制約を満たしつつフロンティアに近づけるために、ある入力を上げてでも全体を減らす改善を選択する傾向が強い。改善目標の変化としては、第一層の目標として 7/8 がより選ばれやすくなっている。この場合の運転時間の削減は全使用量の 5.7% である。

これら制約の設定方法や対象システムの違いは分析方法自体には影響しないため、本論では実例として室内機 A、B、C を含むシステム 1 に対して、表 8 の結果に対して省エネ施策の議論をさらに続ける。

表 10: 改善目標に至るために必要な改善量に基づくクラス分類

改善経路			運用時間削減量				
DMU	改善前	目標	室内機 A	室内機 B	室内機 C	合計	クラス
13	7-26	8-26	107	1	41	149	3
21	8-17	7-24	80	112	44	236	1
20	8-6	7-5	75	-82	243	236	2
23	8-20	8-26	118	-82	136	172	2
17	8-3	7-24	43	112	1	156	1
11	7-21	7-24	48	136	-24	160	1
25	8-24	7-1	15	122	39	176	1
24	8-23	7-24	34	132	22	188	1
18	8-4	7-24	40	145	-24	161	1
29	8-31	7-1	45	148	3	196	1
27	8-27	7-24	90	60	68	218	3
19	8-5	8-26	2	113	44	159	1
15	7-29	7-1	-2	201	29	228	1
9	7-19	7-8	-6	-32	268	230	4
6	7-12	7-1	15	203	16	234	1
28	8-30	7-8	-2	1	234	233	4
26	8-26	7-24	4	152	-8	148	1
16	8-2	7-24	102	207	-86	223	5
7	7-13	8-19	67	30	139	236	3
4	7-06	7-8	-38	-38	311	235	4
14	7-27	8-19	95	14	98	207	3
12	7-24	7-8	-43	-99	303	161	4
10	7-20	7-8	-6	-115	283	162	4
8	7-14	8-19	90	8	126	224	3
3	7-5	7-8	-3	138	83	218	1
2	7-2	8-19	50	42	98	190	3




図 36: 分類されたクラスをより簡易に捉えた図

表 11: 分類されたクラス毎の各平均改善量

クラス	室内機 A	室内機 B	室内機 C	クラスに属する DMU の数
1	26.7	142.8	18.75	12
2	96.5	-82.0	189.5	2
3	83.2	25.8	95.0	6
4	-19.0	-56.6	279.8	5
5	102.0	207.0	-86.0	1

表 10 は各 DMU とその改善対象、それに必要な改善量と分類されたクラスを示す。この分類によって、どの日の改善方法がどの日の改善方法に近いのか理解することができる。加えて、表 11 は表 10 の改善量をクラス分類毎に平均したものである。この結果によると全改善パターンは5つに分類され、それぞれに特徴を見出すことができる。分類されたクラスのうち、クラスの平均削減量でマイナスを含まないものはクラス1と3であり、クラス1は室内機Bのみを大幅に削減するパターンで、クラス3は室内機AとCを大幅に削減するパターンである。マイナスの平均削減量を含むのは、クラス2とクラス4とクラス5であり、クラス2は室内機Bの運用を増やしてでも他の室内機の運用を減らすような改善で、クラス4は室内機Cに大きな改善幅があるが室内機AとBに対しては増えてしまうパターンである。クラス5は1日のみ該当するので本論では特異なケースとして取り扱わないこととする。

表 11 をより捉えやすく図示したものが図 36 である。これら結果を踏まえると、この空調システムの運用履歴によれば、主要な4パターンの改善方策を該当する日に提案することができる可能性があり、特に効果的なのはもっとも件数が多いパターン1であるといえる。本論では、改善パターンのうち、該当日数が多いクラス1、3、4についてより詳細な結果を分析することで、具体的な方策や示唆を明らかにする。




図 37: クラス 1 室内機 A の 8/17 と 7/24 の運用時刻の違い

4.2.2 各クラスの詳細分析




図 39: クラス 1 室内機 C の 8/17 と 7/24 の運用時刻の違い

まずクラス 1 の代表値として 8/17 のデータを扱う。この日の改善目標日は 7/24 であり、このクラスは室内機 B を特に削減する必要があるパターンである。図 38 によると、改善目標である 7/24 は、朝と夜の差分に加え日中に使用している時間が短い時刻があることが明らかである。しかし改善対象である 8/17 も、常に運用し




図 38: クラス 1 室内機 B の 8/17 と 7/24 の運用時刻の違い

続けている訳ではなく、一時間のうちに使用していない時間も存在するため、ユーザーは状況に応じて空調機器をオフにしている。これは空調機器の運用に全く気をつけていないわけではないことを示している。実際にユーザーとオーナーにヒアリングした結果この見解が正しいことが示された。より注意して運用することで早く空調運転をオフにすることができる可能性があるが、それを実現できるかどうかは、ユーザーが意図せずに長く運用していたか、必要性があってその時間を運用していたかどうかによる。本論はその可能性を提示するのみにとどまる。一方、図 37 と図 39 によると、室内機 A と C は夜と朝にのみ差分があることがわかる。逆に日中に 60 分間使い続けている時刻があることが意味するのは、基本的にオンにしたままの運用であり、ユーザーが空調機器のオンオフには無関心であることである。さらにこの場合では、改善目標も同様に日中は常にオンであるため、この結果からではどのように改善すれば良いか提案することはできない。ただし、より良いと評価された日であってもオンにしたままの運用である、ということは意味がある結果であり、改善につなげることができる。実際に、建物オーナーによる調査をおこなったところ、この室内機はユーザーが気にすることなく日中オンにしたままになっていることが明らかになった。これをもとに、ユーザーに必要性を感じなくなった場合に停止操作をしてもらうように依頼することで、無駄に使用している運用を削減することにつながる。この行動の結果は次のシーズンのデータに反映されるため、再度この分析手法を行うことで、ユーザー行動の違いを確認できるようになることも期待できる。




図 40: クラス 3 室内機 A の 7/26 と 8/26 の運用時刻の違い




図 41: クラス 3 室内機 B の 7/26 と 8/26 の運用時刻の違い




図 42: クラス 3 室内機 C の 7/26 と 8/26 の運用時刻の違い

次にクラス 3 の代表値として 7/26 のデータを扱う。この日の改善目標日は 8/26 であり、このクラスは室内機 A と C を大きく削減する必要があるパターンである。図 40 と図 42 が示すように、この場合は夜に消す時刻と朝の起動時刻に差分が発生していることがわかる。クラス 1 の場合にも、室内機 A と C については夜と朝の起動と停止時刻には差分があったので、広く共通する特徴のようでもある。こういった場合には、夜の特定時刻に自動的に空調機器に停止信号を送る手段がとられることが多い。部屋を出る直前に空調オフの制御を行うよりも、オフィスを出る時刻が判明している場合はその数十分前にオフにすることで、快適性に大きな影響を与えずに使用時間を減らすことができるからである。また日中に関してはクラス 1 と同様、運用時間はつけっぱなしになっているため同様の削減提案が可能である。室内機 B に関してはクラス 1 の代表値とは異なり、図 41 によると日中の運用にもほとんど違いがないように見える。全体を通じては使われ方が異なる日があるが存在しているが、クラス 3 に属する日については室内機 B の運用は同様なパターンが多いと言える。




図 43: クラス 4 室内機 A の 7/19 と 7/8 の運用時刻の違い




図 44: クラス 4 室内機 B の 7/19 と 7/8 の運用時刻の違い




図 45: クラス 4 室内機 C の 7/19 と 7/8 の運用時刻の違い

最後にクラス 4 の代表値として 7/19 のデータを扱う。この日の改善目標日は 7/8 であり、このクラスは室内機 C を大きく削減する必要があるパターンである。図 43 と図 44 が示すように、室内機 A と B にはあまり差が見られない。しかし、図 45 によると、室内機 C には夜の停止時刻に大きな違いが見られる。これは定期的に早く業務が終わる日があることを示しており、空調機器の運用を改善するための情報としては有効ではないと言える。実際に建物オーナーによる調査でも同じ見解であった。




図 46: 室内機 A における改善すべき時間帯に該当する日数




図 47: 室内機 B における改善すべき時間帯に該当する日数




図 48: 室内機 C における改善すべき時間帯に該当する日数

クラス毎の分析に加えて、図 46、図 47、図 48 は表 8 の改善量を各室内機毎にヒストグラム化したものであり、どの時間帯に差分が発生していたかを明らかにする。これによると、室内機 A は夜と朝の違いのみであり、室内機 B と C は日中にも違いがあることがわかった。各クラスの代表例による違いでは、室内機 C は日中の違いは見ることはできなかったが、この統計量によってその違いが明らかになった。つまり、室内機 A の日中はユーザーが制御に無関心であるが、室内機 C の日中は室内機 B ほどではないが制御する必要があるという意識を持っていることがわかる。

最後に、全体をまとめた省エネルギー施策は図 49 である。クラス 1 より、室内機 B については日中にユーザーがオンオフする意識を強く持っているが、より効果的に操作されている日が存在するので、その要因を特定することで運用時間を改善できる可能性がある。またクラス 3 より、室内機 A と C に関しては、夜間の停止時刻を管理することで運用を改善できる可能性がある。加えて特に室内機 A の日中の運用に関してユーザーは無関心であるため、必要性を問うことや消すことができる場合に消してもらうことによって、運用が改善する可能性がある。また 5 件該当するクラス 4 の室内機 C の違いは業務時間によるものであるため、省エネ施策には効果的な情報ではない。数値上もっとも効果的なのは日中の室内機 B の運用改善であり、次点が室内機 A と C の夜の自動制御である。室内機 A と C の日中の改善は未知数である。これらを建物オーナーとユーザーに説明した結果、室内機 A と C の夜間の運用停止は集中管理コントローラーから特定時刻に行うようにして、日中の運用については見直す議論を行うことにつながった。以上によって、DEA の結果を分析する




図 49: 分類されたクラスと日毎の比較を加えた情報

ことによって重要な知見を抽出し、省エネ施策を適用するまでに至ることができた。

5 討論

5.1 ケーススタディから得た知見

提案手法を実際に適用した結果、いくつかの重要な知見が得られた。まずユーザーやビルオーナーとしては、実際に運用していた日が証拠となっているため、改善提案の納得性が高く、そのような改善なら可能であるという合意を得ることができた。今回のように、DMU が同じ事業体内の異なる状況を示す場合、意思決定者が実際に運用していた結果のデータが目標値であるということは、実際に改善の納得性を高め受け入れやすい改善提案となることがわかった。次に、DEA の結果をクラス分類することによって得られた結果は非常に有効で、改善方策を分類して観点を絞った対策を実行することができた。その中では特に、日中のほぼ全ての時刻で運転時間が60分であることは、ユーザーが制御に関して無関心であることを示すことがわかった。それを踏まえると、改善候補の日に対しても制御に無関心な状況であるということは、該当期間を通じて対象の室内機に対して制御することに無関心であると言える。この分析によって関心を向けるべき室内機や時間帯を明らかにすることができた。これは空調運用の履歴データを用いる上での限界であり、人感センサーによる制御であればユーザー関心の有無に関わらず無駄になっている可能性のある時間帯の運転は抑えることができる。しかし本手法によって、ユーザーが無関心である室内機が存在するということを特定できるというだけでも有効な情報であり、次シーズンでは日中の運用を気にかけるように働きかけることができれば、運用改善につながる可能性がある。

5.2 適用の制約と今後の課題

本手法では改善量の制約として、運用履歴の統計量から妥当と思われる $C = 240$ という値を設定した。この値はユーザーやビルオーナーと結果を分析する際に変えながら実行することで、結果の解釈をさらに進めることもできる。変動的な制約の場合の重み α も同様であり、データ駆動によって適切と思われる値を設定する方法も必要とされる。また目標とする層についても同様で、今回は第一フロンティアを最終目標として選択していたが、フロンティアを構成する DMU の中に特異な運用があることをユーザーとの間の議論で発見した場合、それを取り除いたフロンティアを用いて分析することも可能である。このような提案手法の柔軟性は、分析者とユーザーやビルオーナーとのインタラクティブな分析と解釈によって有効活用することができると期待できる。

提案手法の前提となっているのは、ユーザーの空調機器の運用履歴が異なることである。そのため、違いが発生しないような運用、つまり管理システムによって完全に制御されユーザーの操作が禁止されている場合には適用しても効果を発揮することができない。また、ユーザーが空調制御に興味がない場合は、操作履歴にデータがほとんど残らないという場合もある。この場合も同様に違いが発生しないため、効果的な分析を行うことができない。つまり、実際に運用していた操作以上には基本的に改善できないということである。これが本手法の制約であり、実例を用いて改善する方法の限界である。さらに、実例を用いる場合はそもそもデータ自体が蓄えられている必要があるため、最低限データを収集して保存する仕組みやある程度の運用期間が必要となる。また、得られた運用時間の違いはその理由を説明することができないため、必要性があってユーザーが制御していたのかそうでなかったのか区別することができない。それはヒアリングを通じて明らかにするか、違いをユーザーが受け止めて可能な範囲で行動に反映することにとどまる。そのため運用改善を保証することはできないという点も本手法の限界である。

今後の課題として残るのは、実例を超えたデータを挿入すること、説明性を向上させること、結果の活用方法を洗練させることである。まず実例を越える範囲については、実際に運用したデータではないが期待する想定運用状況を仮想データとして作り出して、DEA の分析に加えることである。これは、実際の操作履歴よりも大きく改善したい場合、理想的な運用日を加えることで実現する方法である。次は説明性の向上について、例えば気象データなどを連携することで、運用の違いに関する知見を抽出することが期待できる。これら二つは本手法の制約を弱めるためのものである。一方、最後の観点である結果の活用方法を洗練させることは手法の高度化に該当する。本論ではクラス分類を行なった後の分析は、各クラスの代表日と比較するという人に依存する操作であったため、属人的な分析を残している。本論では改善量のみをクラス分類に用いていたが、時刻毎の差分のデータまで分類に用いることで、人の手を介さずに分析できる可能性がある。このような改善が出来ると、より数理的な説明性を保った結果を出力できると期待できる。また、ケーススタディから判明したことで、退社時間が短い日が含まれており、そのような日を通常の日と同一に扱ってしまうと、運用の改善目標としても実現できなくなってしまうという課題がある。このような日を分類して考えるには、DEA 適用前に運用データをなんらかの基準でクラス分類することも有効である可能性がある。さらに建物のより詳細なデータを活用できるなど追加の情報がある場合、既存の他の評価手法であるシミュレーションや回帰モデルを組み合わせることも期待される。例えば、空調能力に対する回帰モデルを作成することが出来ると、機器のパフォーマンスが落ち

る運用時間や方法を明らかにすることで、どの時間帯の運用を減らすべきか詳細に議論することも期待できる。

5.3 結論

空調システムの制御は、ユーザーの情報を用いるための技術的課題や、集中管理コントローラーの機能による制約のため、多くの既設ビルは固定化されたスケジュール設定の運用となっていた。既存の研究は、ユーザーの情報を用いて制御することで、エネルギーのロスを抑えることで10-40%もの電力量の削減見込みがあることを示している。しかしながら既設ビルへの適用を考えた際に、エネルギー効率的な制御を可能にするための導入コストは、そのビルの状況に応じて費用対効果を考える必要がある。こういった背景から、限られた条件下であっても簡易的に実行できる省エネ施策や、削減可能なエネルギー量を概算できることは、効果的な省エネ施策対象の選定や、省エネ施策適用の範囲を広げることができるという意味で重要である。本研究は上記の目的のもとで取り組んだものである。

省エネ施策を実施するには、何らかの方法でエネルギー使用状況を評価する必要がある。ビルエネルギーにおける手法では、少ない条件で初期段階で用いられるのはDEAである。DEAはビルエネルギーにおいて応用事例が数多くあるが、空調運用に焦点をあてた研究は我々の調査の範囲では確認できなかった。本研究では、DEAによって空調運用を評価して省エネ施策を適用するため、エネルギーマネジメントの実務面の調査と、対象となる空調システムであるVRFシステムの使用状況の調査を行った。その結果、実現可能性を高めてユーザーに受け入れやすい提案を行う必要があることと、VRFシステムの運用時間はユーザーによる制御によって異なる場合が多いことがわかった。この場合、DMUとして室内機の総運用時間を多次元入力として扱い、さらにDEAの実現可能性についての研究結果を応用することで、受け入れやすい提案を実現した。さらに、多くのDEAの応用がベンチマークとしての評価までを対象としている中、本論ではその結果を用いた具体的な省エネ施策を実施する方法まで提案した。その方法は、結果をクラス分類して特徴を解釈することで、ユーザーにこういった施策が有効であるかということを示すことであった。

本研究は、ケーススタディとして提案手法をあるオフィスビルにおいて適用することで、その有効性を評価した。結果によると、全ての日に対して改善を実現することができれば、ある系統においてはおよそ7.5%の運用時間を削減できる可能性があることがわかった。さらにその結果を分析することで、集中管理コントローラーへの設定や、ユーザーへの示唆を実際に与え、省エネ施策として実施した。このケー

ススタディからはいくつかの有効な知見を得ることができ、今後の課題につながる要因を発見することができた。本提案手法は、空調運用を改善したいオーナーに対して省エネ施策を提案するためのものであり、1.3.1 章における外部の専門家や、ビルデータを用いた商材を扱う企業などが想定使用者である。以上の内容は、空調運用履歴のデータを用意することができれば適用可能であるため、目的としている省エネ施策を実行できる対象を広げることが可能である。また、本手法は 3.1 章で紹介しているように、段階的な改善の際に全体のデータが更新される可能性がある場合、分野を問わず適用することができる。

6 付録 オープンソースソフトウェア開発

6.1 背景

Python は科学計算における分野でユーザーが多く、2021 年に行われた Stack Overflow の調査では、Python ユーザーはおよそ 50%にも上ることが示されている [71]。しかしながら研究を開始した 2019 年時点では、Python の DEA のライブラリが存在せず、本研究は数理最適化の Python ライブラリである PuLP [72] を活用しつつ、最適化の定式化部分や階層 DEA に関しては自作しつつおこなっていた。その後、何件かの DEA のライブラリが登録されたが、sklearn [73] のようにコード上で分析できるものではなくアプリケーションで実行されるものや、機能が非常に少なくメンテナンスされていないもののみであった。R 言語においては Benchmarking [74] という充実したライブラリが存在するが、R 言語は Stack Overflow の調査ではおよそ 5%ほどのユーザーしか存在しない。分析やシステム開発を行う上では、複数の言語よりも同一の言語で実行できる方が望ましい場合が多い。そのため、コード上で完結した扱いやすく機能が豊富にある DEA の Python ライブラリがあれば、DEA の分野の発展に貢献できると考え、本研究と並行しながらオープンソースソフトウェア (OSS) の開発を実施するに至った。

GitHub によると、OSS にコントリビュートすることはやりがいがあり、思い描くどんなスキルに対しても、学習し、教え、経験を積むことができると言われている [75]。OSS に開発者が参加する理由は様々で、すべての OSS はパブリックであるため、活動をどこでも自由に紹介できる事例を得られるというメリットもある。さらに、このような活動をしていることを採用条件にする企業も存在し、その活動の価値は高く評価されている。また本やレシピ、リストや授業もオープンソースプロジェクトとして開発され、多くの人々の役に立っている。

一方で、OSS の開発のためには、品質の担保のためのテストや、メンテナンス性の高いコードを書く必要性、他者の参加を容易にするような開発環境やドキュメントの整備が必要になる場合がある。これらを経験して身に付けることは、研究者として今後アルゴリズムを開発して公開する際に、非常に重要なスキルと考えられる。さらにアルゴリズムについて OSS を作成することは、ドキュメントの整備や実装のために、ロジックの理解をより深く求められるため、この分野の研究者としての知見を深めるためにも有効であると考えられる。



図 50: PyPI で公開している画面

6.2 DEA ライブラリ Pyfrontier

開発した DEA の OSS は Pyfrontier と名づけ、図 50 が示すように PyPI 上に公開することで、`pip install` によって誰でも活用できる状態とした。さらに図 51 のように、GitHub 上に公開して Python の対応バージョンやドキュメントへのリンク、OSS としての要望やバグ報告を Issue や Discussion に記載できるように、窓口として機能している。この Pyfrontier のロゴは出力指向のモデルによるフロンティアを元に作成したものである。ここではさらに、coverage としてテストによるコードの網羅率を可視化することで、利用者としての安全性も確保している。

図 52 は OSS の開発に貢献したい人向けに開発手順を説明したものである。このように整備することで、さまざまなユーザーが参画し、よりよい機能を追加したりバグを改善し、ドキュメントを充実させることでソフトウェアを改善しつづけることができる。これは継続的な開発が前提となっており、品質を保つためのテスト自動化やビルドの自動化が必要となる。このような自動化の領域は一般に DevOps と呼ばれ、ソフトウェア開発において重要な技術である [76]。




図 51: GitHub 上のリポジトリの画面




図 53: GitHub pages の機能によるチュートリアル

Contribution Guidelines

We appreciate any efforts that help us to make this module better! You can help with code, reporting error or adding document.

There are some ways to sophisticate this project:

- Implement a feature
 - If you have some functions or idea about DEA, please open an issue first to discuss.
- Complement document
 - Unfortunately, the tutorial is not yet sufficient. It would be helpful if you could add the missing information.
- Refactor code
 - If you find a better implementation than the existing code, please let us know.
- Report a bug
 - If you find a bug, please report it. It is an opportunity to strengthen the reliability of the module.
- Add an advanced application
 - The idea of applying DEA is to increase creativity for the user. If you come up with one, please open an issue.

Issue Guidelines

図 52: Contribution ガイド

The screenshot shows the Pyfrontier documentation website. On the left is a sidebar with a search bar and a table of contents. The table of contents includes 'Tutorial' and 'Input oriented model'. The main content area is titled 'Fit dea model.' and contains the following text: 'The necessity inputs are inputs and outputs. The result has below belongings.' Below this is a code block showing the following Python code:

```
dea = EnvelopDEA("CRS", "in")
dea.fit(
    supply_chain_df[["day", "cost"]].to_numpy(),
    supply_chain_df[["profit"]].to_numpy(),
)
dea.result[0]
```

Below the code block is the output: 'Out: EnvelopResult(score=1.0, id=0, dmU=DMU(input=array([1, 5]), output=array([15]), id=0), we

図 54: チュートリアル各機能の詳細

OSS におけるドキュメントは非常に重要であり、その中でも使い方を示すチュートリアルの整備は必須である。コードを用いた説明や可視化については Sphinx と呼ばれる OSS がよく用いられる [77]。図 53 のように、全ての機能は一覧として表示され、各機能のページでは、図 54 のようにサンプルコードによって利用方法を説明している。このように OSS として公開するためにどのような情報が必要で、どのような状態を提供することが必要であるかは、機械学習のパラメータ最適化アルゴリズムである Optuna [78] という OSS を参考に整備した。




図 55: bib ファイルをパースして各機能のページで補足

さらに本 OSS の独自の要素として、実装されている機能のもととなる論文については、bib ファイルをパースすることで図 55 のように参考文献として表示している。この bib ファイルの読み込みは OSS である BibtexParser によるものである [79]。このように明記することで、各手法を用いるユーザーが、より深い知識を必要とする際に役立つと期待している。

6.3 おわりに

OSS は多くの人の目に触れることで改善され、その透明性から信頼性が担保されている。本論で開発した OSS も、数理最適化部分には OSS である PuLP を用いており、さまざまな分析ライブラリもこのように相互に利用しあって完成している。今後はさらに、DEA における先進的な手法の実装や、その他にも意思決定に関わるアルゴリズムについても、拡充していきたいと考えている。この取り組みを論文の付録として残すことは、OSS 開発という活動も存在するということを広げる可能性があるという意味で、またそのハードルを下げるという意味でも、少なからず貢献できると期待している。このように本研究を通じて手法の新規性や応用のみでなく、その手法を多くのユーザーが使えるような状態にすることにも取り組んでいくことで、DEA の分野の発展に貢献することが出来れば幸甚である。

参考文献

- [1] G. Aydin, “The modeling of coal-related co2 emissions and projections into future planning,” *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, vol. 36, no. 2, pp. 191–201, 2014.
- [2] G. Aydin, “Regression models for forecasting global oil production,” *Petroleum Science and Technology*, vol. 33, no. 21-22, pp. 1822–1828, 2015.
- [3] L. Pérez-Lombard, J. Ortiz, and C. Pout, “A review on buildings energy consumption information,” *Energy and buildings*, vol. 40, no. 3, pp. 394–398, 2008.
- [4] J. C. Lam, C. Tsang, and L. Yang, “Impacts of lighting density on heating and cooling loads in different climates in china,” *Energy Conversion and Management*, vol. 47, no. 13, pp. 1942–1953, 2006.
- [5] M. Zimmermann, H.-J. Althaus, and A. Haas, “Benchmarks for sustainable construction: A contribution to develop a standard,” *Energy and Buildings*, vol. 37, no. 11, pp. 1147–1157, 2005.
- [6] J. Laustsen, *Energy efficiency requirements in building codes, energy efficiency policies for new buildings. ie a information paper*, 2008.
- [7] K. Chua, S. Chou, W. Yang, and J. Yan, “Achieving better energy-efficient air conditioning –A review of technologies and strategies,” *Applied Energy*, vol. 104, pp. 87–104, 2013.
- [8] M. J. Mendell, W. J. Fisk, K. Kreiss, *et al.*, “Improving the health of workers in indoor environments: Priority research needs for a national occupational research agenda.,” *American journal of public health*, vol. 92 9, pp. 1430–40, 2002.
- [9] N. Aste, M. Manfren, and G. Marenzi, “Building automation and control systems and performance optimization: A framework for analysis,” *Renewable and Sustainable Energy Reviews*, vol. 75, pp. 313–330, 2017.
- [10] Y. Agarwal, B. Balaji, R. Gupta, J. Lyles, M. Wei, and T. Weng, “Occupancy-driven energy management for smart building automation,” 2010, pp. 1–6.

- [11] V. L. Erickson, Y. Lin, A. Kamthe, *et al.*, “Energy efficient building environment control strategies using real-time occupancy measurements,” in *Proceedings of the First ACM Workshop on Embedded Sensing Systems for Energy-Efficiency in Buildings*, New York, NY, USA, 2009, 19–24.
- [12] Z. Zhang and K. P. Lam, “Practical implementation and evaluation of deep reinforcement learning control for a radiant heating system,” in *Proceedings of the 5th Conference on Systems for Built Environments*, 2018, pp. 148–157.
- [13] T. Morinibu, T. Noda, and T. Shota, “Application of deep reinforcement learning in residential preconditioning for radiation temperature,” in *2019 8th International Congress on Advanced Applied Informatics (IIAI-AAI)*, 2019, pp. 561–566.
- [14] M. Hu, F. Xiao, and L. Wang, “Investigation of demand response potentials of residential air conditioners in smart grids using grey-box room thermal model,” *Applied Energy*, vol. 207, pp. 324–335, 2017.
- [15] L. Yu, S. Qin, M. Zhang, C. Shen, T. Jiang, and X. Guan, “A review of deep reinforcement learning for smart building energy management,” *IEEE Internet of Things Journal*, vol. 8, no. 15, pp. 12 046–12 063, 2021.
- [16] D. Lindelöf and N. Morel, “A field investigation of the intermediate light switching by users,” *Energy and Buildings*, vol. 38, no. 7, pp. 790–801, 2006.
- [17] A. Mahdavi, A. Mohammadi, E. Kabir, and L. Lambeva, “Occupants’ operation of lighting and shading systems in office buildings,” *Journal of Building Performance Simulation*, vol. 1, no. 1, pp. 57–65, 2008.
- [18] T. Teixeira and A. Savvides, “Lightweight people counting and localizing in indoor spaces using camera sensor nodes,” in *2007 First ACM/IEEE International Conference on Distributed Smart Cameras*, 2007, pp. 36–43.
- [19] S. P. Tarzia, R. P. Dick, P. A. Dinda, and G. Memik, “Sonar-based measurement of user presence and attention,” in *Proceedings of the 11th International Conference on Ubiquitous Computing*, New York, NY, USA, 2009, 89–92.
- [20] L. J. Lo and A. Novoselac, “Localized air-conditioning with occupancy control in an open office,” *Energy and Buildings*, vol. 42, no. 7, pp. 1120–1128, 2010.

- [21] D. Zhu, E. Pritchard, S. R. Dadam, V. Kumar, and Y. Xu, “Optimization of rule-based energy management strategies for hybrid vehicles using dynamic programming,” *arXiv preprint arXiv:2207.06450*, 2022.
- [22] T. A. Nguyen and M. Aiello, “Energy intelligent buildings based on user activity: A survey,” *Energy and Buildings*, vol. 56, pp. 244–257, 2013.
- [23] O. Masoso and L. Grobler, “The dark side of occupants’ behaviour on building energy use,” *Energy and Buildings*, vol. 42, no. 2, pp. 173–177, 2010.
- [24] G. Halhoul Merabet, M. Essaaidi, M. Ben Haddou, *et al.*, “Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques,” *Renewable and Sustainable Energy Reviews*, vol. 144, p. 110 969, 2021.
- [25] H. Liang, J. Ma, R. Sun, and Y. Du, “A data-driven approach for targeting residential customers for energy efficiency programs,” *IEEE Transactions on Smart Grid*, vol. 11, no. 2, pp. 1229–1238, 2020.
- [26] W. Chung, “Review of building energy-use performance benchmarking methodologies,” *Applied Energy*, vol. 88, no. 5, pp. 1470–1479, 2011.
- [27] E. Borgstein, R. Lamberts, and J. Hensen, “Evaluating energy performance in non-domestic buildings: A review,” *Energy and Buildings*, vol. 128, pp. 734–755, 2016.
- [28] A. Charnes, W. Cooper, and E. Rhodes, “Measuring the efficiency of decision making units,” *European Journal of Operational Research*, vol. 2, no. 6, pp. 429–444, 1978.
- [29] T. Sueyoshi, Y. Yuan, and M. Goto, “A literature study for dea applied to energy and environment,” *Energy Economics*, vol. 62, pp. 104–124, 2017.
- [30] R. Rostamzadeh, O. Akbarian, A. Banaitis, and Z. Soltani, “Application of dea in benchmarking: A systematic literature review from 2003–2020,” *Technological and Economic Development of Economy*, vol. 27, no. 1, pp. 175–222, 2021.
- [31] S. Önüt and S. Soner, “Energy efficiency assessment for the antalya region hotels in turkey,” *Energy and Buildings*, vol. 38, no. 8, pp. 964–971, 2006.

- [32] W.-S. Lee, "Benchmarking the energy efficiency of government buildings with data envelopment analysis," *Energy and Buildings*, vol. 40, no. 5, pp. 891–895, 2008.
- [33] W.-S. Lee and K.-P. Lee, "Benchmarking the performance of building energy management using data envelopment analysis," *Applied Thermal Engineering*, vol. 29, no. 16, pp. 3269–3273, 2009.
- [34] J. Lu, B. Ashuri, and M. Shahandashti, "A data envelopment analysis model for building energy efficiency benchmarking," in *Construction Research Congress 2014*. 2014, pp. 1073–1082.
- [35] E. Wang, Z. Shen, N. Alp, and N. A. Barry, "Benchmarking energy performance of residential buildings using two-stage multifactor data envelopment analysis with degree-day based simple-normalization approach," *Energy Conversion and Management*, vol. 106, pp. 530–542, 2015.
- [36] B. Ashuri, J. Wang, M. Shahandashti, and M. Baek, "A data envelopment analysis (dea) model for building energy benchmarking," *Journal of Engineering, Design and Technology*, vol. 17, no. 4, pp. 747–768, 2019.
- [37] C. P. Timmer, "Using a probabilistic frontier production function to measure technical efficiency," *journal of Political Economy*, vol. 79, no. 4, pp. 776–794, 1971.
- [38] P. W. Wilson, "Detecting influential observations in data envelopment analysis," *Journal of productivity analysis*, vol. 6, no. 1, pp. 27–45, 1995.
- [39] R. D. Banker and H. Chang, "The super-efficiency procedure for outlier identification, not for ranking efficient units," *European journal of operational research*, vol. 175, no. 2, pp. 1311–1320, 2006.
- [40] N. A. Tran, G. Shively, and P. Preckel, "A new method for detecting outliers in data envelopment analysis," *Applied Economics Letters*, vol. 17, no. 4, pp. 313–316, 2010.
- [41] A. Emrouznejad and G. R. Amin, "Dea models for ratio data: Convexity consideration," *Applied mathematical modelling*, vol. 33, no. 1, pp. 486–498, 2009.

- [42] T. Sueyoshi and M. Goto, “Returns to scale and damages to scale under natural and managerial disposability: Strategy, efficiency and competitiveness of petroleum firms,” *Energy economics*, vol. 34, no. 3, pp. 645–662, 2012.
- [43] R. D. Banker and R. C. Morey, “Efficiency analysis for exogenously fixed inputs and outputs,” *Operations Research*, vol. 34, no. 4, pp. 513–521, 1986.
- [44] F. Yu and K. Chan, “Improved energy management of chiller systems by multivariate and data envelopment analyses,” *Applied Energy*, vol. 92, pp. 168–174, 2012.
- [45] S. Xin, H. Xu, S. Li, W. Wang, J. Guo, and W. Yang, “Efficiency evaluation of a floor standing air conditioner with different installation positions and air supply parameters applied to a large laboratory,” *Journal of Building Engineering*, vol. 32, 2020.
- [46] M. Q. Raza and A. Khosravi, “A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings,” *Renewable and Sustainable Energy Reviews*, vol. 50, pp. 1352–1372, 2015.
- [47] J. H. Lee, P. Im, and Y.-h. Song, “Field test and simulation evaluation of variable refrigerant flow systems performance,” *Energy and Buildings*, vol. 158, pp. 1161–1169, 2018.
- [48] Z. J. Zhai and J. Rivas, “Promoting variable refrigerant flow system with a simple design and analysis tool,” *Journal of Building Engineering*, vol. 15, pp. 218–228, 2018.
- [49] C. Kani-Sanchez and R. Richman, “Incorporating variable refrigerant flow (vrf) heat pump systems in whole building energy simulation—detailed case study using measured data,” *Journal of Building Engineering*, vol. 12, pp. 314–324, 2017.
- [50] W. Goetzler, “Variable refrigerant flow systems,” *ASHRAE Journal*, vol. 49, Apr. 2007.
- [51] X. Lin, H. Lee, Y. Hwang, and R. Radermacher, “A review of recent development in variable refrigerant flow systems,” *Science and Technology for the Built Environment*, vol. 21, no. 7, pp. 917–933, 2015.

- [52] G. Zhang, H. Xiao, P. Zhang, *et al.*, “Review on recent developments of variable refrigerant flow systems since 2015,” *Energy and Buildings*, vol. 198, pp. 444–466, 2019.
- [53] X. Zhou, D. Yan, J. An, T. Hong, X. Shi, and X. Jin, “Comparative study of air-conditioning energy use of four office buildings in china and usa,” *Energy and Buildings*, vol. 169, pp. 344–352, 2018.
- [54] T. Hong, D. Yan, S. D’Oca, and C.-f. Chen, “Ten questions concerning occupant behavior in buildings: The big picture,” *Building and Environment*, vol. 114, pp. 518–530, 2017.
- [55] G. Zhang, X. Li, W. Shi, B. Wang, and Y. Cao, “Influence of occupant behavior on the energy performance of variable refrigerant flow systems for office buildings: A case study,” *Journal of Building Engineering*, vol. 22, pp. 327–334, 2019.
- [56] L. Seiford and J. Zhu, “Context-dependent data envelopment analysis - measuring attractiveness and progress,” *Omega*, vol. 31, no. 5, pp. 397–408, 2003.
- [57] S. Lim, H. Bae, and L. Lee, “A study on the selection of benchmarking paths in dea,” *Expert Systems with Applications*, vol. 38, no. 6, pp. 7665–7673, 2011.
- [58] N. Ramón, J. Ruiz, and I. Sirvent, “Two-step benchmarking: Setting more realistically achievable targets in dea,” *Expert Systems with Applications*, vol. 92, pp. 124–131, 2018.
- [59] S. Lozano and L. Calzada-Infante, “Computing gradient-based stepwise benchmarking paths,” *Omega (United Kingdom)*, vol. 81, pp. 195–207, 2018.
- [60] J. Park and S.-I. Sung, “Integrated approach to construction of benchmarking network in dea-based stepwise benchmark target selection,” *Sustainability (Switzerland)*, vol. 8, no. 7, pp. 1–15, 2016.
- [61] T. R. Sexton, R. H. Silkman, and A. J. Hogan, “Data envelopment analysis: Critique and extensions,” *New Directions for Program Evaluation*, vol. 1986, no. 32, pp. 73–105, 1986.
- [62] J. Doyle and R. Green, “Efficiency and cross-efficiency in dea derivations, meanings and uses,” *Journal of the Operational Research Society*, vol. 45, no. 5, pp. 567–578, 1994.

- [63] Q. An, X. Tao, B. Dai, and B. Xiong, “Bounded-change target-setting approach: Selection of a realistic benchmarking path,” *Journal of the Operational Research Society*, vol. 72, no. 3, pp. 663–677, 2021.
- [64] A. Emrouznejad and A. L. Anouze, “Data envelopment analysis with classification and regression tree—a case of banking efficiency,” *Expert Systems*, vol. 27, no. 4, pp. 231–246, 2010.
- [65] R. J. Tibshirani and B. Efron, “An introduction to the bootstrap,” *Monographs on statistics and applied probability*, vol. 57, pp. 1–436, 1993.
- [66] A. L. M. Anouze and I. Bou-Hamad, “Data envelopment analysis and data mining to efficiency estimation and evaluation,” *International Journal of Islamic and Middle Eastern Finance and Management*, vol. 12, no. 2, pp. 169–190, 2019.
- [67] J. Wu, L. Liang, and F. Yang, “Achievement and benchmarking of countries at the summer olympics using cross efficiency evaluation method,” *European Journal of Operational Research*, vol. 197, no. 2, pp. 722–730, 2009.
- [68] A. Flokou, N. Kontodimopoulos, and D. Niakas, “Employing post-dea cross-evaluation and cluster analysis in a sample of greek nhs hospitals,” *Journal of Medical Systems*, vol. 35, no. 5, pp. 1001–1014, 2011.
- [69] A. Charnes, W. Cooper, L. Seiford, and J. Stutz, “A multiplicative model for efficiency analysis,” *Socio-Economic Planning Sciences*, vol. 16, no. 5, pp. 223–224, 1982.
- [70] D. Davies and D. Bouldin, “A cluster separation measure,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-1, no. 2, pp. 224–227, 1979.
- [71] *Stack overflow developer survey 2021*, <https://insights.stackoverflow.com/survey/2021>, 2021.
- [72] *Pulp*, <https://coin-or.github.io/pulp/>.
- [73] *Scikit-learn*, <https://scikit-learn.org/stable/index.html>.
- [74] P. Bogetoft and L. Otto, *Benchmarking*, <https://cran.r-project.org/web/packages/Benchmarking/index.html>.
- [75] *Open source guides*, <https://opensource.guide/ja/how-to-contribute/>.

- [76] C. Ebert, G. Gallardo, J. Hernantes, and N. Serrano, “Devops,” *IEEE Software*, vol. 33, no. 3, pp. 94–100, 2016.
- [77] *Sphinx*, <https://www.sphinx-doc.org/ja/master/>.
- [78] *Optuna*, <https://github.com/optuna/optuna>.
- [79] *Bibtexparser*, <https://bibtexparser.readthedocs.io/en/master/>.

謝辞

本論文は著者の大阪大学大学院情報科学研究科・情報数理学専攻における研究の成果をまとめたものです。

本研究を進めるにあたり、大阪大学大学院情報科学研究科・情報数理学専攻 森田浩教授には、研究室訪問や研究の着手から完了まで、終始一貫して懇切丁寧なご指導を賜りました。当初のアイデアである DEA の改善が空調制御のパフォーマンスに与える影響の研究から、ジャーナルからのフィードバックと再調査によって研究の方向性を大きく変えることになり、主となる論文の採択まで紆余曲折ありました。その中でも森田浩教授からは、一つ一つのアイデアや疑問にフィードバックとアドバイスをいただくことができ、その結果、研究内容を深掘りして研究の価値を高めることができました。特に、こういった内容がこの研究領域に本質的に貢献するのか、という観点でのご指摘は、今後の研究者としての指針となる重要な考え方として受け取りました。筆者としては、これら観点は今後の業務における応用研究を進めるにあたり、研究として価値ある応用研究を行うための基礎となると考えております。また、査読をご担当頂いた藤崎泰正教授、鈴木秀幸教授、山口勇太郎准教授からも多大なフィードバックを頂くことで、本論文の質を高めることができたことも、ここに感謝いたします。筆者の仕事上の都合もご考慮いただき、業務と研究を並行して行うことが出来たことは、社会人として博士課程を専攻することにご理解が深くあったためであり、これらがなければこのように本論文をまとめ上げることは難しく、ここに改めて心より感謝の意を表します。

ダイキン工業株式会社 サービス本部の方々には、本論文をまとめるに当たり、エネルギーマネジメントの運用上の観点に関して多くの貴重なご意見を賜りました。加えて、上長や所属チームの開発メンバーの方々にも、業務負荷を調節していただくなどの協力が必要不可欠でした。また、著者の博士後期課程修了まで応援して下さった妻に心より感謝いたします。ここに記して関係者の方々に深く謝意を表します。

2023 年 1 月 森嶋 武史