

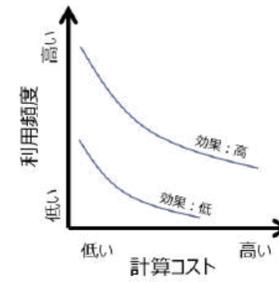
Building Environment Simulation × AI

株式会社日建設計 飯田 玲香 八登 千佳

Simulation

特徴と課題

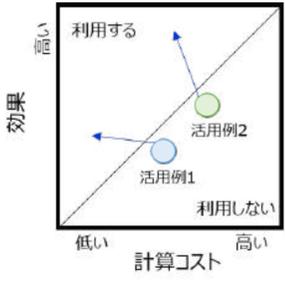
数値シミュレーションは、物理現象やシステムの挙動をモデル化することで、過去の経験が無い未知の領域であっても予測が可能である。但し、モデルを細分化して解くことで予測精度を高めるため、通常は多くのパラメータ設定や計算コストを要する。また、計算コストが高いことで数値シミュレーションに至らず、その効果が十分に認識されていないことが考えられる。右図には、シミュレーションの利用頻度に対する、計算コストと効果の関係性を示す。計算コストが小さく、得られる効果が高いほど、シミュレーションの利用頻度が高まることが考えられる。



Simulation

× AI
意義と活用例

AI 予測モデルは、学習データが無い未知の領域の予測が行えない反面、学習範囲内であれば、高速・高精度な予測が可能である。ここでは、シミュレーション利用を促進する AI の活用例を紹介する。シミュレーションを行うか否かは、計算コストの利用効果のバランスと考えられる。活用例の1つ目は、計算コストを下げた「効率化」、2つ目は、シミュレーションの価値を向上した「高度化」を期待した事例である。



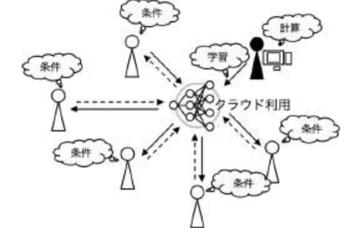
効率化

活用例 1

Simulation 目的や条件が同様のシミュレーションが、複数のプロジェクトで行われる。人的なリソースの制約から利用できない場合もある。



Simulation × AI 多くのプロジェクトで標準的に利用できる予測モデルにより、計算コストが低減され、クラウドの活用で利用者の拡大に繋がる。



冬期ペリメータの温熱環境

試験公開 → <http://ns-env-ai.com/apps/app1>

背景・目的

ペリメータ空間では、暖房時のコールドドラフトや上下温度差による温熱環境の悪化が懸念されるため、設計初期段階でペリメータの温熱環境を把握することが重要である。ここでは、Deep Neural Network (DNN) にて構築した予測モデルを、設計の初期段階で活用する方法を検討する。

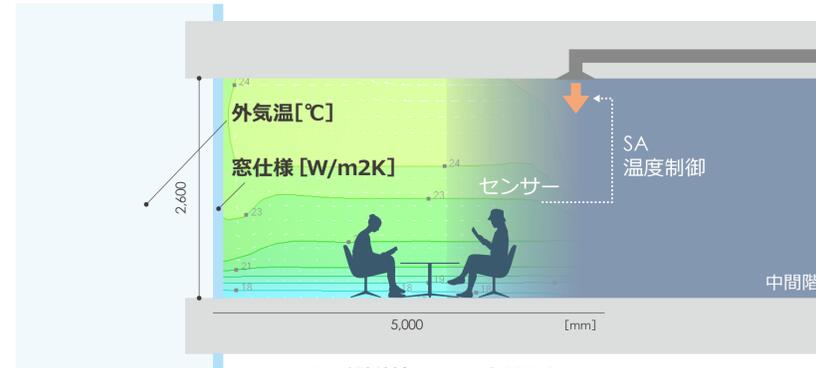


図 a 解析対象ペリメータ断面イメージ

解析条件

基礎的検討として図 a に示す簡易なペリメータ断面 (2次元) の定常乱流モデルを対象とする。検討ケースを図 b、CFD 解析条件を表 a に示す。

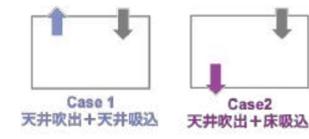


図 b 検討ケース

表 a CFD 解析条件

| 対象空間 | 奥行(5.0m)×天井高(2.6m) ※2次元 |
|--------------|-------------------------|
| 窓面 | フルハイト(2.6m) |
| 設定温度(センサー位置) | 18-26[°C] (表1) |
| 空調風量 | 10 [回/h] (風速:1 [m/s]) |
| 空調吹出温度 | 22-50 [°C] (設定温度に制御) |
| 上層温度 | 空調室、対象室と同じ |
| 下層温度 | 隣室温度差係数: 0-1[-] (表1) |
| 内部発熱 | なし |

検討フロー

図 c に示す 1~4 のフローで検討を行う。

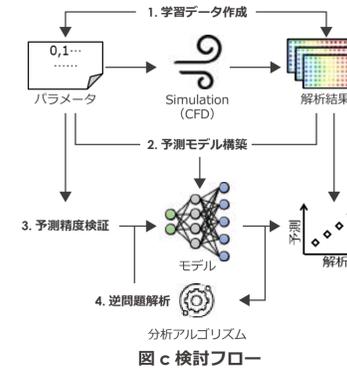


図 c 検討フロー

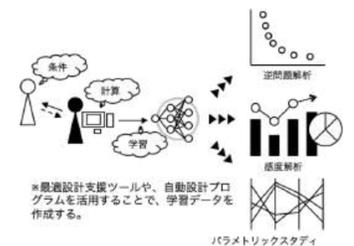
高度化

活用例 2

Simulation 計算コストが高いシミュレーションは、人的、時間的なリソースをかけても、あまり多くの検討を行えない。



Simulation × AI プロジェクトに特化した予測モデル※により、計算コストが高い高度な分析が行える。



省エネ効果検討

背景・目的

脱炭素社会に向け、建築物の省エネ・ZEB 化は必須の課題となりつつあり、その解決にあたっては、設計段階からシミュレーションを活用した検討を行うことが効果的である。ここでは、DNN にて構築した予測モデルにより、省エネ設計のための高度な活用方法について検討する。尚、シミュレーションツールは、BEST 省エネ基準対応ツール v.3.0.4 (開発者版) とする。

解析条件

図 d に示す 12 階建て 30,000m² の偏心コアの事務所ビルを対象とする。外気負荷は中央熱源方式の空冷ヒートポンプ (HP) チラー、室負荷は個別分散熱源方式の電気式ヒートポンプチラー (EHP) にて処理する。ベースとなるケースの結果を図 e に示す。

検討フロー

PAL* 及び年間一次エネルギー消費量の予測モデルを作成し、それぞれ予測精度の検証、及び最適化等の分析アルゴリズムと組み合わせさせた検討を行う (図 f 1~4 のフロー)。

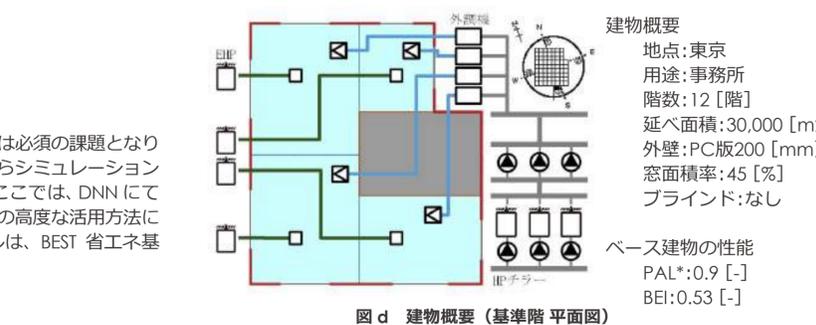


図 d 建物概要 (基準階 平面図)

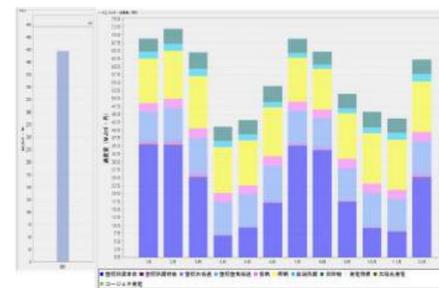


図 e ベースのケースの結果 (左: PAL*, 右: 月別一次エネルギー)

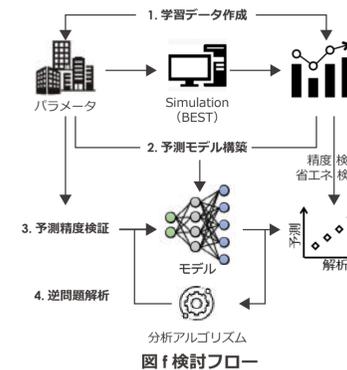


図 f 検討フロー

1. 学習データ作成

I PAL*

離散変数を含むサンプリング

サンプリング数を 1,000 (検証用: 100) とし、表 I-1 を設計変数とした LHS を行う。

表 I-1 PAL* 計算の設計変数

| 設計変数 | 条件等 | *ベース |
|--------|--|------|
| 庇長さ | 0 ~ 200 [mm] (連続変数) | *100 |
| 断熱厚 | 30 ~ 150 [mm] (連続変数) | *30 |
| 窓種類 ID | 1: 単板ガラス 8 mm, 2: 複層ガラス 8 mm, 3: 高性能熱反射ガラス 8 mm, 4: 日射遮蔽型 Low-E+透明, 5: 日射遮蔽型 Low-Eアルゴン層+透明, 6: ブライド* 内蔵透明+高日射遮蔽型 Low-E+透明, 7: トリプル真空ガラス (離散変数) | |

2. Deep Neural Network の構築

I PAL*

表 I-1 の設計変数を入力値、PAL* (冷房) と PAL* (暖房) を出力値とする予測モデルを構築する。また、学習量の違いによる精度を比較するため、学習量を 900、450、90 に変えたモデルも作成する (以降、予測モデルの「900」、「450」、「90」と呼ぶ。)

II 一次エネルギー

自動設計プログラムの組み込み

サンプリング数を 1,000 (検証用: 100) とし、年間一次エネルギー消費量を目的変数、表 II-1 に示す各項目を設計変数とした LHS を行う。ここでは、設計変数の数値を元に、複数の入力条件を変更できる自動設計を行うプログラムを組み込む。

表 II-1 年間一次エネルギー消費量計算の設計変数

| 設計変数 | 条件 | 設計変数の説明 |
|-----------------------|-------------|--------------|
| COP比[-] センtral | 0.75 ~ 2.23 | ベースCOPに対する比率 |
| ファン効率[-] | 0.6 ~ 0.9 | 外調機のファン効率 |
| 外気量 [CMH/人] | 20 ~ 50 | 外調機の外気量 |
| 全熱交換効率 [%] | 0 ~ 90 | 外調機的全熱交換効率 |
| COP比[-] パッケージ | 0.95 ~ 2.62 | ベースCOPに対する比率 |
| 照明[W/m ²] | 3.0 ~ 16.3 | 照明の消費電力 |
| 太陽光発電[kW] | 0 ~ 1,800 | 太陽光発電の容量 |

II 一次エネルギー

II 一次エネルギー

表 II-1 の設計変数を入力値、空調、換気、照明、給湯熱源、昇降機、コンセント、太陽光発電の年間一次エネルギーを出力値とした予測モデルを構築する。尚、PAL* と同様、学習量の違いによる精度を比較する。

3. 予測精度の検証

空気温度の RMSE 値は 0.04 [°C] ※ Case2

全ての予測モデルの予測値と計算値との絶対誤差を図 3-1,2、予測値と計算値の散布図を図 3-3,4 に示す。天井吸込みの Case1 の方が誤差は大きいものの全体的によく一致しており、予測モデルが「900」の Case2 の空気温度の RMSE 値は 0.04°C となった。学習量が少ないほど予測精度は低下するが、学習量が「90」の場合でも、比較的高い予測精度を示している。

検証用のサンプルの中から抽出した 2 条件 (No.919, No.995) の結果比較を図 3-5 ~ 3-8 に示す。どのモデルでも、比較的良好に予測されることが分かる。

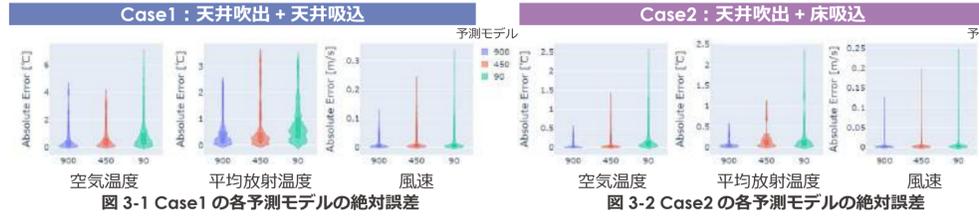


図 3-1 Case1 の各予測モデルの絶対誤差

図 3-2 Case2 の各予測モデルの絶対誤差

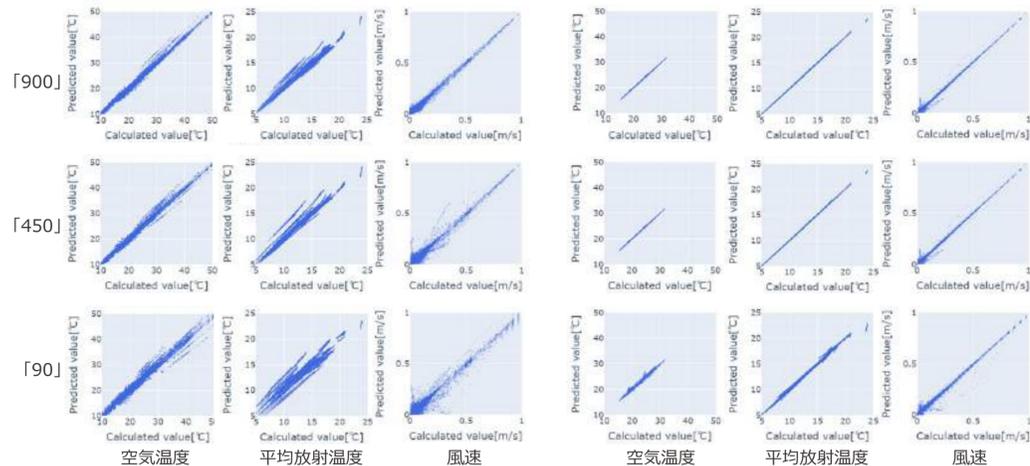


図 3-3 Case1 の各予測モデルの予測値と計算値の散布図

図 3-4 Case2 の各予測モデルの予測値と計算値の散布

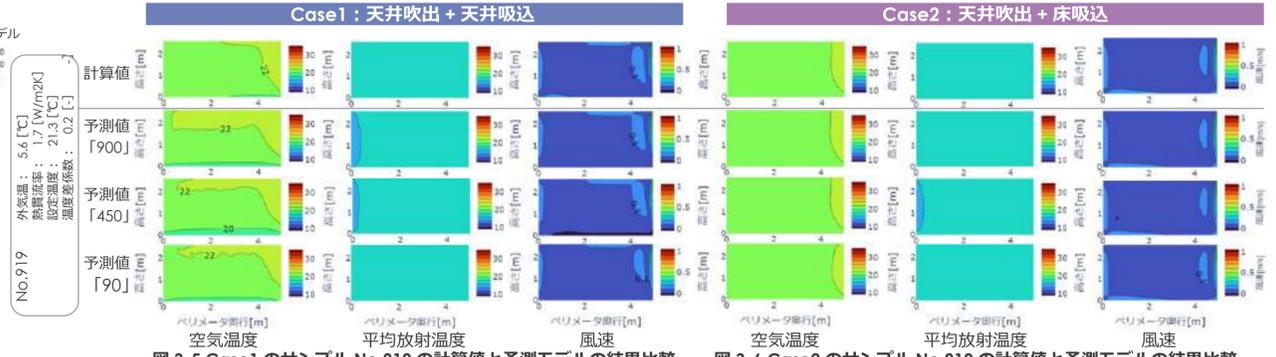


図 3-5 Case1 のサンプル No.919 の計算値と予測モデルの結果比較

図 3-6 Case2 のサンプル No.919 の計算値と予測モデルの結果比較

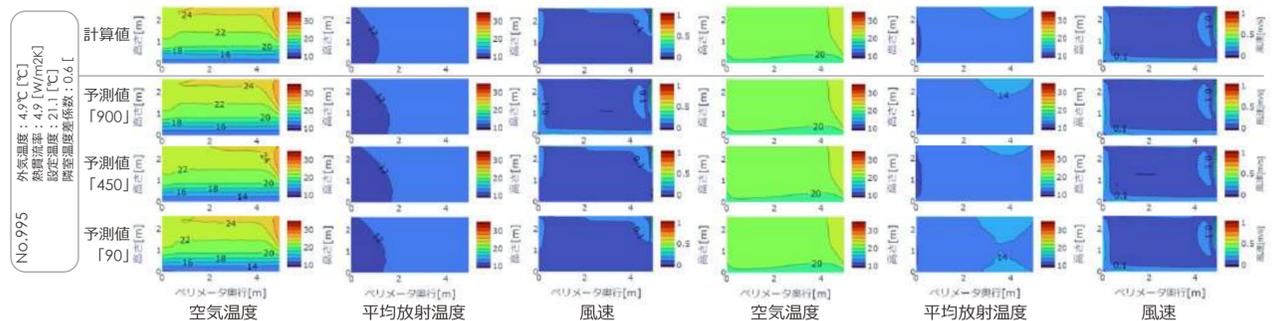


図 3-7 Case1 のサンプル No.995 の計算値と予測モデルの結果比較

図 3-8 Case2 のサンプル No.995 の計算値と予測モデルの結果比較

4. 予測モデルを活用した逆問題解析

対象エリアの PMV と上下温度差を目的変数としたパラメトリックスタディ

対象エリアの PMV と上下温度差を目的変数とした LHS (100 sample) を行う。計算条件を図 4-1 及び表 4-1、結果を図 4-2,3 に示す。

PMV が -0.5 ~ 0.5 [-], 上下温度差が 3 [°C] 以内になるサンプル数は、Case2 の床吸込の方が多く、特に上下温度差が小さくなる傾向がある。



図 4-1 設計変数と目的変数

表 4-1 計算条件

| 項目 | 条件 |
|-------------------|------|
| 外気温 (OT) [°C] | -5,5 |
| 設定温度 (set_T) [°C] | 22 |
| 隣室温度差係数 (f) [-] | 0.1 |

PMV 算出条件: 代謝量: 1.2 [met], 着衣量: 1.1 [clo], 湿度: 40 [%]

目的 PMV を満たす窓仕様の探索

対象エリアの目標 PMV を満たす窓性能 (熱貫流率 [W/m2K]) を探索する。尚、目標変数の PMV は、-0.2、-0.5、-0.7 とし、計算条件は表 4-1 とする。

最適値を図 4-4、その時の PMV、PPD、空気温度、平均放射温度、風速分布を図 4-5 ~ 4-10 に示す。外気温 -5°C で PMV -0.2 を満たすには、両 Case ともに高い断熱性能が必要であるが、これ以外の場合、足元に冷気が溜まりにくい Case2 の方が窓性能を緩和できる可能性がある。

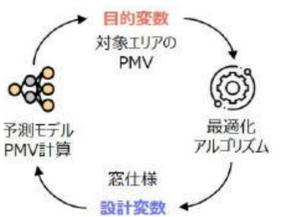


図 4-2 Case1 のパラメトリックスタディの結果 (平行座標プロット)

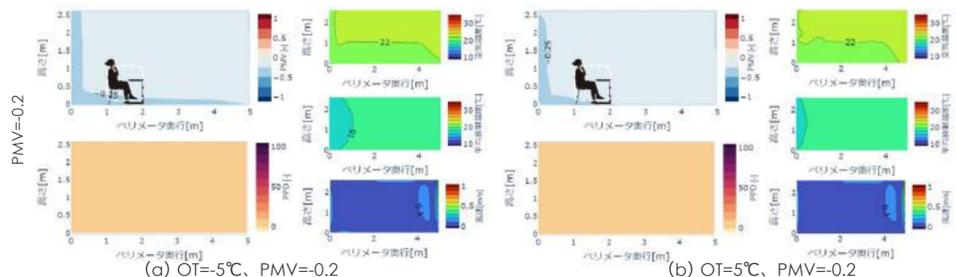


図 4-5 Case1 の目標 PMV [-] が -0.2 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

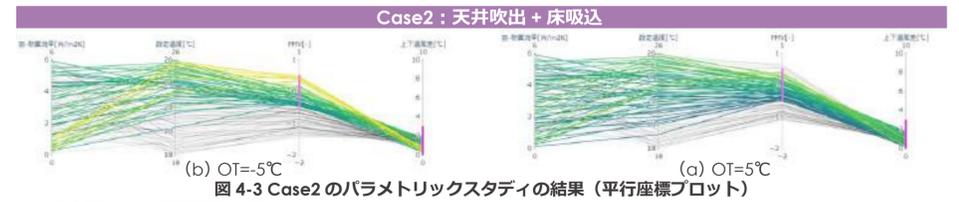


図 4-3 Case2 のパラメトリックスタディの結果 (平行座標プロット)

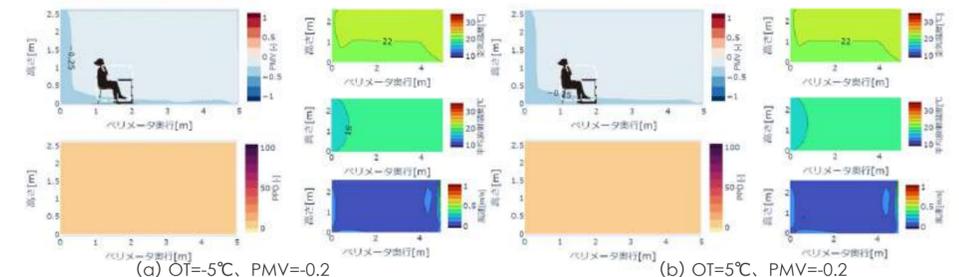


図 4-6 Case2 の目標 PMV [-] が -0.2 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

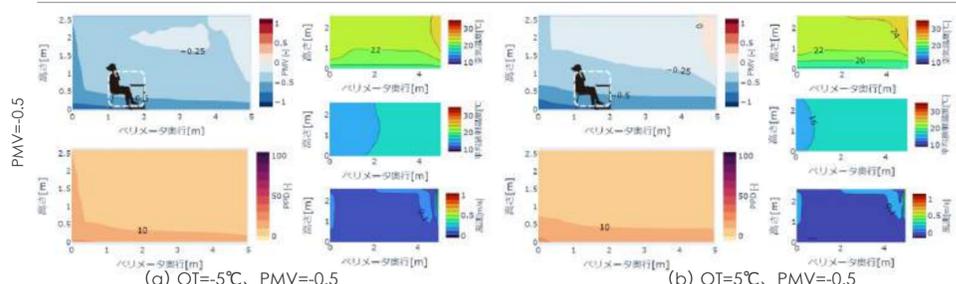


図 4-7 Case1 の目標 PMV [-] が -0.5 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

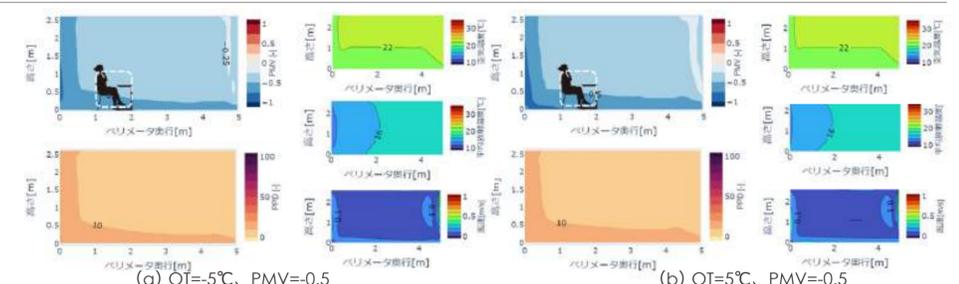


図 4-8 Case2 の目標 PMV [-] が -0.5 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

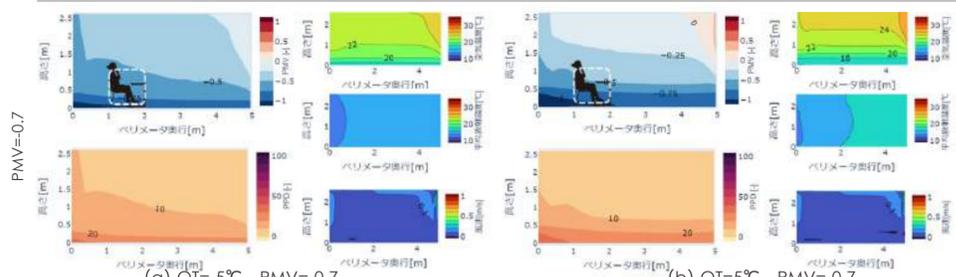


図 4-9 Case1 の目標 PMV [-] が -0.7 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

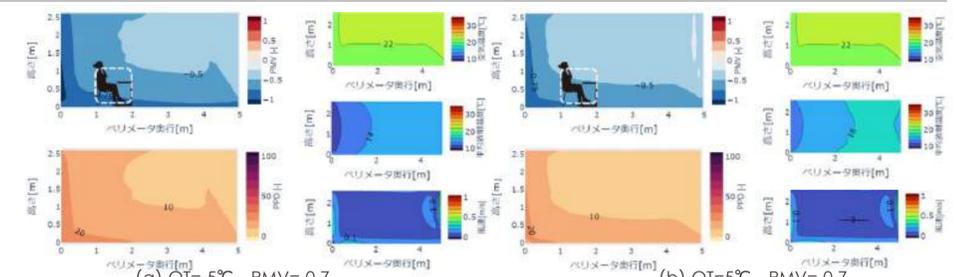


図 4-10 Case2 の目標 PMV [-] が -0.7 の場合の PMV、PPD、空気温度、平均放射温度、風速分布の結果

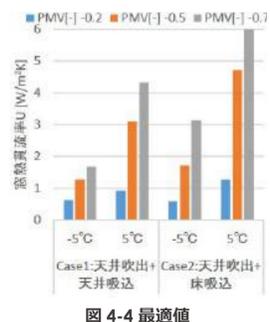


図 4-4 最適値

3. 予測精度の検証

I PAL*

「900」と「450」は同等

予測値と計算値の平均二乗誤差 (RMSE 値) を図 I-3-1 に示す。学習データが多いほど RMSE は小さいが、「900」と「450」の予測精度は概ね同等となった。

PAL*(冷房)、PAL*(暖房)の絶対誤差を図 I-3-2、予測値と計算値の散布図を図 I-3-3 に示す。冷房の方が、やや誤差が小さい傾向がある。

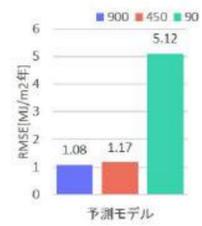


図 I-3-1 各予測モデルの RMSE 値

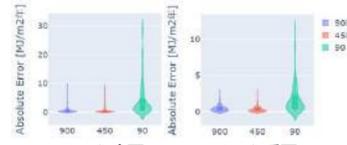


図 I-3-2 各予測モデルの絶対誤差

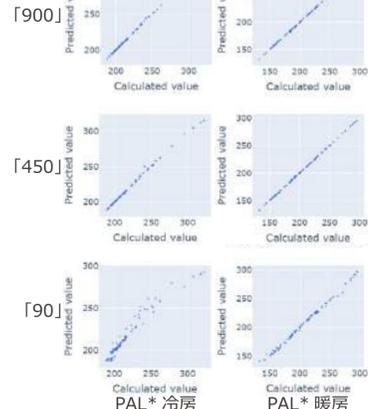


図 I-3-3 各予測モデルの予測値と計算値の散布図

II 一次エネルギー

誤差は 1%

予測値と計算値の RMSE 値を図 II-3-1 に示す。学習データ量が多いほど RMSE は小さく、ベースに対する相対誤差は、「90」の場合で 1% 程度であった。一次エネルギーの項目ごとの絶対誤差を図 II-3-2、散布図を図 II-3-3 に示す。絶対値が大きい項目は、相対的に誤差が大きくなる傾向がある。

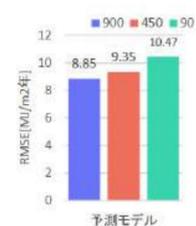


図 II-3-1 各予測モデルの RMSE 値

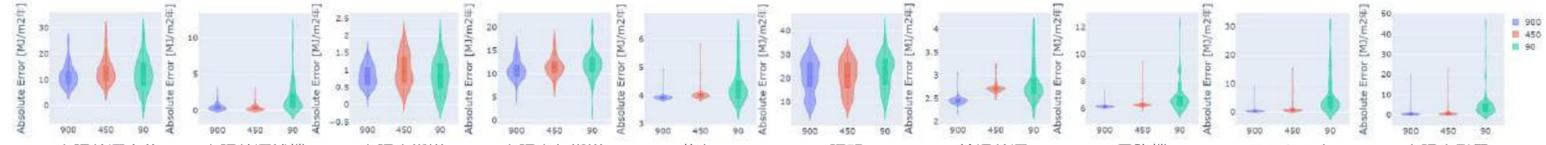


図 II-3-2 各予測モデルの絶対誤差

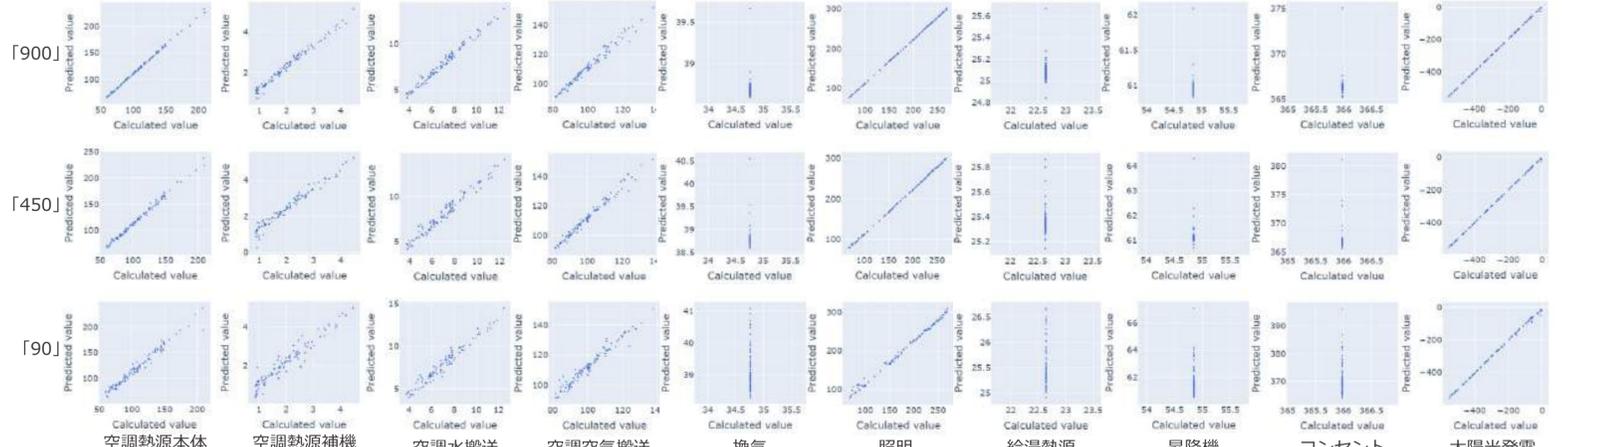


図 II-3-3 各予測モデルの予測値と計算値の散布図

4. 予測モデルを活用した逆問題解析

I PAL*

各設計変数の感度分析

窓ガラスの種類 (ID) ごとに、庇長さや断熱厚さを設計変数としたパラメトリックスタディを行う。各設計変数を 10 個のパーティションで区切り、計 121 ケースの検討を行う。

PAL*(冷房)、PAL*(暖房)及び、PAL*を図 I-4-1 に示す。断熱厚さは、PAL*(暖房)を低減する効果があり、庇長さは、PAL*(冷房)を低減、PAL*(暖房)を増加させる傾向がある。

PAL*とコストの多目的最適化

窓ガラスの種類 (ID) ごとに、庇長さや断熱厚さを設計変数とし、PAL*とインシャルコストを目的変数とした多目的最適化を行う。尚、インシャルコストについては、建物全体を想定し、断熱 1mm 当たり 2 百万円、庇長さ 1mm 当たり 3 百万円と仮定した。多目的最適化の結果を図 I-4-2 に示す。窓 ID1: 単板ガラス 8mm と、窓 ID2: 複層ガラス 8mm は、比較的費用対効果が高い。

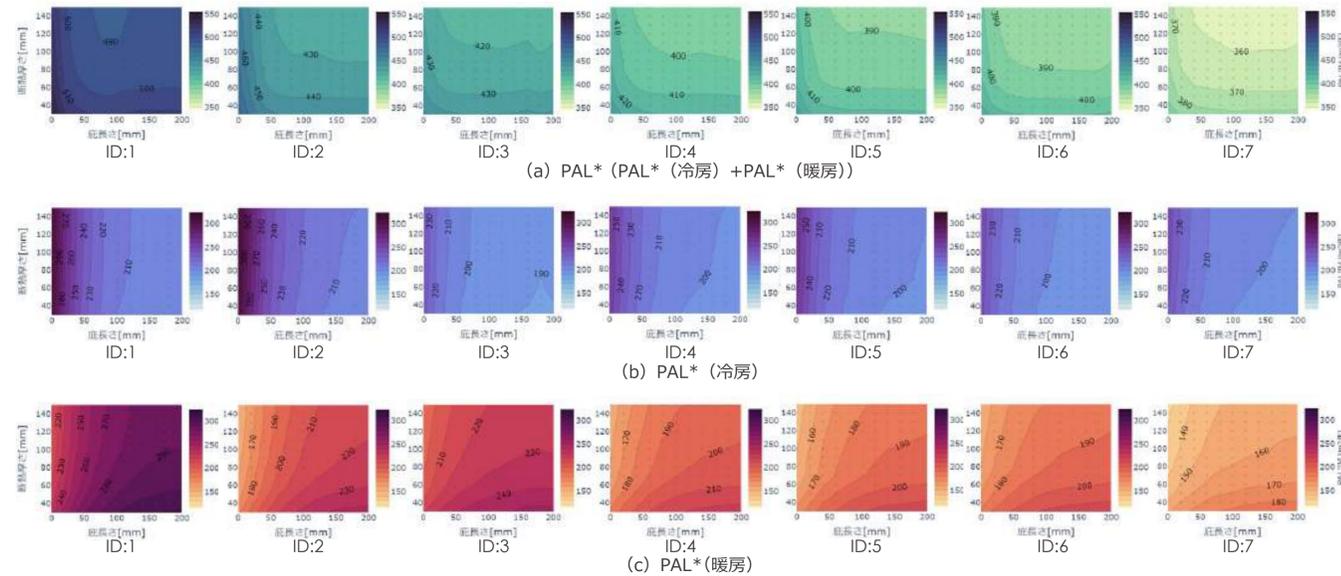


図 I-4-1 窓ガラス種類 (ID) 別の PAL* の感度分析結果

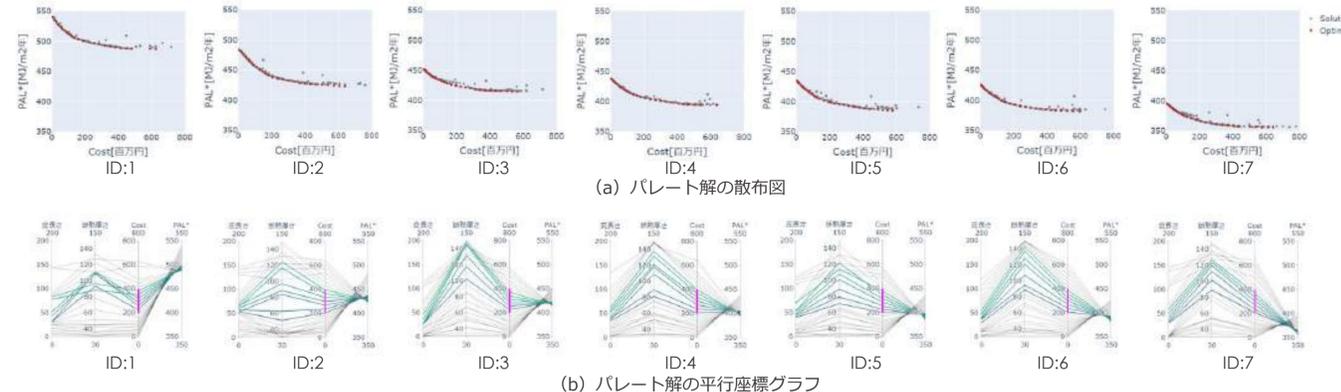


図 I-4-2 窓ガラス種類 (ID) 別の PAL* とインシャルコストを目的変数とした多目的最適化

II 一次エネルギー

グローバル感度解析による優先順位検討

目的変数を一次エネルギー消費量の合計、空調合計、空調熱源本体、空調水搬送、空調空気搬送とした sobol 法によるグローバル感度解析を行う。設計変数の条件範囲が表 II-1 の場合を Case1、表 II-4 の場合を Case2 とする。

図 II-4 に、各入力変数に対する寄与率 (S1) と、交互作用を加味した寄与率 (ST) の結果を示す。Case2 では「一次エネルギー」に対する「照明」と「太陽光発電」の寄与が同等となり、「空調 - 合計」に対する「全熱交換効率」の寄与が相対的に大きくなる。

設計変数の設計範囲を変更し、各設計変数の寄与率を示すことで、設計可能な条件下での採用手法の優先順位を決定することが可能となる。

表 II-4 Case2 の条件

| 設計変数 | 条件 (範囲) |
|------------------------|------------|
| COP比 (セントラル) [-] | 0.75 ~ 1.5 |
| ファン効率 [-] | 0.6 ~ 0.65 |
| 外気量 [CMH/人] | 30 ~ 50 |
| 全熱交換効率 [%] | 0 ~ 70 |
| COP比 (パワーカー) [-] | 0.95 ~ 1.5 |
| 照明 [W/m ²] | 8.0 ~ 16.3 |
| 太陽光発電 [kW] | 0 ~ 600 |

*Case1 からの変更部分はアンダーライン

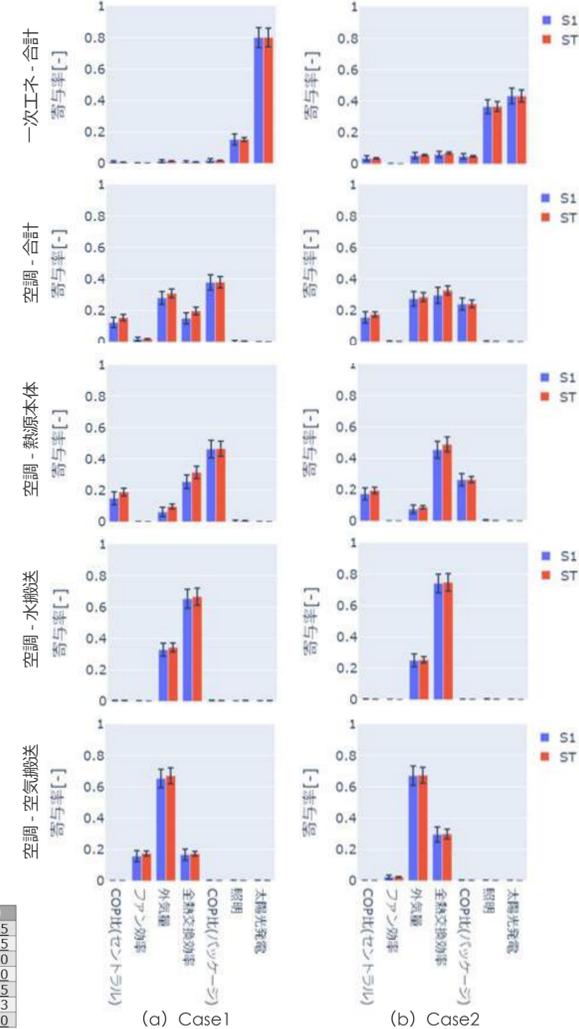


図 II-4 グローバル感度解析の結果