

遠隔エネルギーマネジメントのための用途別エネルギー消費パターン認識法の研究

(名古屋大学) ○田中 英紀 *
(名古屋大学) 鶴飼 真貴子 **

エネルギーマネジメント 遠隔管理 エネルギー消費
パターン分析 消費予測 説明因子

研究の目的

本研究では、建物設備の遠隔モニタリングで収集可能な用途別エネルギー消費・室内環境・外界気象などの各種データにもとづく、データ駆動型エネルギーマネジメント手法を検討した。この分析手法には機械学習を用い、これを展開する上で事前に整理・提案すべき事項として、(1) 用途別エネルギー消費予測法と重要説明因子の特定、(2) パターン分析を用いた運用上の不具合検知法の開発、という2テーマを取り上げて検討した。

研究の内容

(1) エネルギー消費予測法と重要説明因子の特定

大学研究棟の大部屋研究室（評価は514・518号室の2/4ユニット：72 m²）に対し、用途別エネルギー消費量と室利用状況などのデータを収集するとともに、Azure Machine Learning Studio (MS 社) を用いて線形・非線形回帰分析を行い、エネルギー消費予測モデルを作成した。次に、この予測精度を確認することで、a. 予測のためのデータ処理方法、b. 高精度な予測モデルの選定、c. 重要説明変数の特定（用途別エネルギー消費と在室者や室内外環境データとの因果関係の分析）などを考察した。

表1に学習及び評価に用いた説明変数の一覧を示す。予測対象のエネルギー消費は、対象居室2室のエアコン消費電力、各室のコンセント・照明電力である。

① 単相相関による重要説明因子の把握

冷房・暖房期間と中間期を対象に、上記の用途別エネルギー消費量と各説明変数の単相相関分析を行い、エネルギー消費量と各説明変数の基本的な因果関係を把握した。

この結果、在室データは他と比べて各電力消費量との相関係数が大きくなり、重要な説明変数であることを確認した。また、エアコン電力は外気温に比較的強い相関、日射量に弱い相関があり、ドア開放時間には相関がない。照明電力量は、室照度に弱い相関があることを把握した。

② エネルギー消費予測モデルの選定

前述の機械学習ソフトにより多変量線形帰式、ベイズ線形回帰、ランダムフォレスト(決定木的一种)、ニューラルネットワークなどの分析法を用いて「室外機・照明・コンセント」の各電力量予測モデルを作成した。分析は、一日(24時間の連続データ)を一単位として、取得データの半分を学習データ、残り半分を評価データに使い、かつ学

習・評価データに各曜日が概ね50%ずつ分配されるよう抽出して行っている。また、この分析結果を簡易に比較検討できる分析ツールをBIソフトにより構築した(図1)。

開発ツールでは、算出されたエネルギー消費の予測値と実績値の比較(時系列データ)、学習モデルおよび評価データに対する予測精度(決定係数)、実績データに対する予測結果の散布図、在室者データの有無などを表示する。また、決定木などの非線形回帰では回帰式が直接導出されないため、モデルの説明変数の重要度を考察するための指標にPFI(Permutation Feature Importance) =PS-PBを設定し、この結果も表示する。ここにPB:学習データを予測した場合の精度(決定係数)、PS:学習データ内の1説明変数の値をランダムに置換して予測した精度である。

③ランダムフォレストによる予測精度と重要説明因子

用途別エネルギー消費の予測精度は、ランダムフォレストで最も高くなり、決定係数が多変量線形回帰(重回帰)に比べて2~3倍程度高くなった。また、多変量線形回帰およびランダムフォレストでは、夏期・冬期ともに在室人数+有無データを追加すると、学習データ・評価データでの決定係数は向上する傾向を示した。

(2) パターン分析を用いた運用上の不具合検知法の開発

①運用不具合に関する検知手法の概要

クラスタ分析を用いて用途別エネルギー消費パターンを分類するとともに、正常時の消費パターンから逸脱するパターンを抽出して異常確認を行う手順の異常検知手法を提案した。このクラスタ分析にはk-means++法を用い、先の(1)の取得データを用いて具体的に検討を行った。

提案した不具合検知フローを図3に示す。一般に、正答データの学習のために不具合データを定義し、手作業で学習データから不具合データを予め除外して学習に用いるプロセスを、プレクラスタリングと本クラスタリングを組み合わせた分析で解決する手法を提案した。

②不具合判定における閾値の与え方

学習段階では、データ間の距離にもとづいて学習データを任意のクラスタ数(k個)に分類し、分類された各クラスタデータからその重心を算出する。

検証段階では、検証データの最近傍クラスタ重心(類似パターン)を求め、その距離を異常度として判定に用いる。異常度の判定には予め閾値を設定し、それを超過し

表 1 学習及び評価に用いた説明変数の一覧

※グレーハッチが変数限定で考慮した説明変数

番号	項目	番号	項目	番号	項目	番号	項目
1	月	9	在室人数平均 514 号室	18	平均室温	27	外気温
2	日	10	在室人数最大 514 号室	19	最大室温	28	外気相対湿度
3	時	11	在室人数最小 514 号室	20	最小室温	29	日射量
4	曜日	12	在室人数平均 518 号室	21	平均室内相対湿度	30	室内外温度 514+518 号室
5	平均 CO2 濃度	13	在室人数最大 518 号室	22	最大室内相対湿度	31	在室有無 514 号室
6	最大 CO2 濃度	14	在室人数最小 518 号室	23	最小室内相対湿度	32	在室有無 518 号室
7	最小 CO2 濃度	15	在室人数平均 514+518 号室	24	平均室照度	33	在室有無 514+518 号室
8	1 時間内 ドア開放状況	16	在室人数最大 514+518 号室	25	最大室照度	34	国民の祝日
		17	在室人数最小 514+518 号室	26	最小室照度	35	年

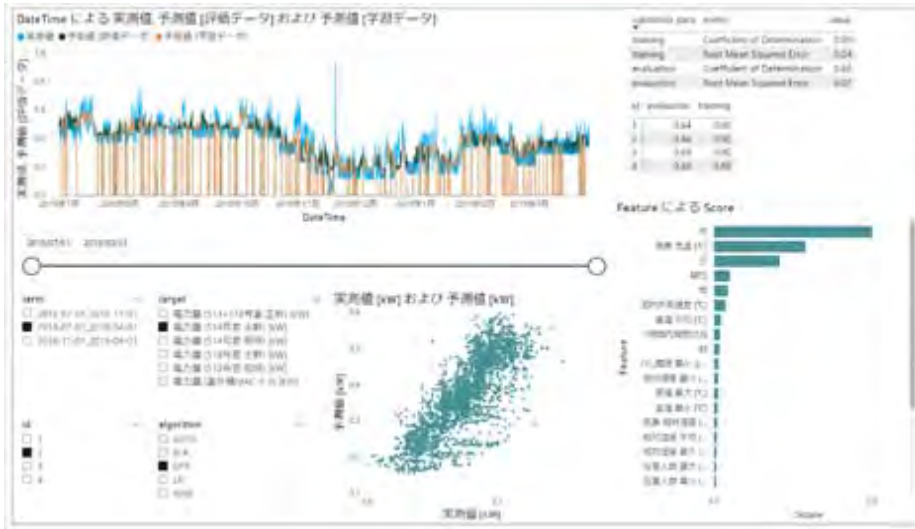


図 1 分析結果比較ツールの概要

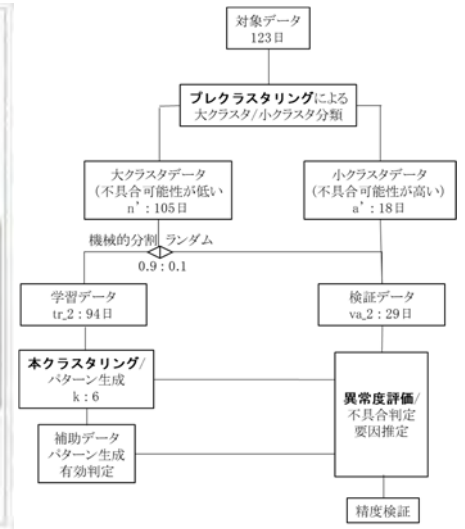


図 2 パターン分類による不具合検知フロー

た場合に異常と判定する。この閾値は(1)式による最近傍クラスタの重心と各学習データとの距離の最大値とし、(2)式のようにその閾値を上回る場合に異常判定とした。ここに、 a :異常度、 x :学習データ、 x_c :クラスタ重心、 x' :検証データ、 c :クラスタ番号、 c' :最近傍クラスタ番号

$$a(x') = \min_c \left\{ \sqrt{\sum_{i=1}^{24} (\bar{x}_{c,i} - x'_i)^2} \right\} \quad a(x') > \max_{c'} \{ a(x_{c'}) \} \quad \dots(1) \quad \dots(2)$$

③ 不具合検知の結果

試算では、プレクラスタリングで $k=10$ を仮定して分類状況を確認し、小クラスタを除いて 123 日から 105 日に分析対象データを絞った。このうち学習データに 94 日分を抽出し、 $k=6$ として本クラスタリングを行い、検証データ 29 日分に対して、不具合検知診断を行った。結果としては、不具合日数 15 日に対し、照明電力のみを用いた検知手法による不具合日の検知率：12/15、不具合でない日の非検知率：10/10 となり、高い不具合検知率となった。また、室内環境の補助データの異常度を求め、不具合状況も算出した。補助データの不具合度も加味して診断すると、不具合日の検知率は 13/15 と向上した。

研究の成果、新知見

用途別エネルギー消費予測手法では、複数の非線形回帰手法からランダムフォレストが最も予測精度が高くなること、説明変数の分析では特に在室者データが重要となることを確認した。パターン分析による運用上の不具合検知法として、k-means++法によるクラスタ分析から電力消費パターンを学習・分類し、検証データを類似パターンと比較して不具合を検知する手法を開発した。また、プレクラスタリングによる振り分けから学習データを抽出する方法も提案し、これらの有用性を示した。

今後の予定

本研究で提案した用途別エネルギー消費予測手法と重要説明因子の特定に関する分析を、長期データ（2年間）を用いて詳細に分析し、これまで得た知見の精査と再整理を行う。また、用途別エネルギー消費予測モデルや不具合検知モデルをオフィス等の他の建物に適用し、この手法の汎用性を検証して手法論の確立を目指す。

謝辞

機械学習モデルの作成においては、(株)ナレッジコミュニケーション：牧村健氏に多大なご支援とご協力を賜った。ここに記して、心より感謝の意を表します。

* 名古屋大学 施設・環境計画推進室

* Nagoya University, Campus Planning & Environment Management Office

**名古屋大学大学院 環境学研究科

** Nagoya University, Graduate School of Environmental Studies