

ブロック定義図による説明変数候補の抽出と 異種混合学習を用いたビル電力需要予測方式

河津 雅忠[†] 妻鹿 利宏[‡] 久代 紀之[†]

[†]九州工業大学 [‡]三菱ビルテクノサービス株式会社

1. はじめに

デマンド制御や省エネ制御を有用に行うには、気温や時間など、その空間に影響を与えている要素を把握する必要がある。本研究では、それらの要素を空間特性と呼ぶ。また、それらの制御に適したビル電力需要予測を行うには、適切な説明変数セットの選定と、説明変数により空間特性が解釈可能な予測式の構築が重要である。しかし、一般的に精度が高いとされる非線形モデルによる予測式では、説明変数を用いて空間特性を解釈することが困難である。

本研究では、適切な説明変数セットの整理・抽出にブロック定義図を用いてビル電力を構成する要素を定義し、定義された要素を場合分け・説明変数の候補とする。また、ブロック定義図で抽出した多数の場合分け・説明変数の候補から異種混合学習技術[1]により線形モデルによる電力需要予測を行う。

2. 説明変数セットの抽出

予測手法には、大きく分けて線形手法と非線形手法がある。線形手法は、目的変数であるビルの消費電力が偏回帰係数と説明変数により、以下の式(1)のように定義されるものとする。

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + \epsilon \quad (1)$$

Y : 目的変数 β_0 : 切片 β_n : 回帰係数 X_n : 説明変数 ϵ : 誤差項

線形式において各説明変数は独立であり、各説明変数が与える目的変数への影響は偏回帰係数として表される。これにより、線形式を用いることで説明変数による空間特性の解釈が可能となる。

しかし、この方法では、線形の予測式に含まれていない説明変数の影響を評価することは不可能なため、有効な制御を行うためには説明変数セットの選定が重要となる。

ビル電力のブロック定義図を図1に示す。これは、省エネ制御やデマンド制御の有識者たちとのブレインストーミングにより、ビル電力を構成する要素を定義したものである。今回は、ブロック定義図に記載されている候補のうち、ビル管理システムデータや気象庁のデータから取得可能な要素を場合分け・説明変数の候補とした。

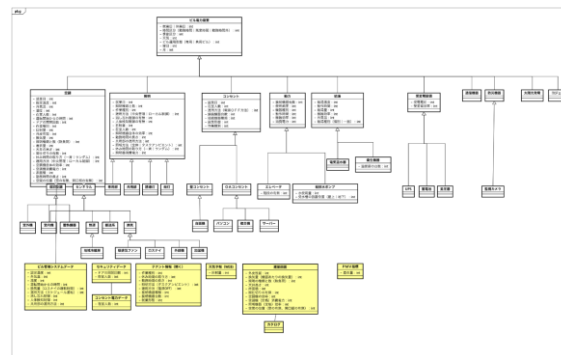


図1:ビル電力のブロック定義図

3. ビル電力需要予測

異種混合学習技術を用いたビル電力需要予測方式について説明する。




図2:異種混合学習技術

異種混合学習技術について図2に示す。異種混合学習とは、場合分け候補の説明変数セットを用いてルール形式でデータを分割し、その分割したデータを説明変数候補の説明変数セットを用いて予測式を構築することで、線形式による予測で高い精度を得る手法である。

異種混合学習の流れについて説明する。異種混合学習では、以下の3つのステップにより学習を行う。

- ① 場合分けの最適化を行う。消費電力値を目的変数とし、各場合分け候補で単回帰を行うことで最も消費電力に影響を与えている説明変数を分割条件とする。
- ② 説明変数の最適化を行う。まず、分割されたデータ間での各説明変数の独立を確保する。その後、最適な説明変数セットを全探索により獲得する。
- ③ これ以上精度を改善できない予測結果があった場合は、それを削除しその前の結果を予測結果とする。

Extraction of explanatory variable candidates by block definition diagram and building power demand prediction method using heterogeneous mixed learning

[†]Masatada Kawatsu, [‡]Toshihiro Mega, [†]Noriyuki Kushiro

[†]Kyushu Institute of Technology

[‡]Mitsubishi Electric Building Techno-Service Corporation

上記アルゴリズムに基づき、Rを用いて、場合分け・説明変数候補を入力することにより、電力需要予測を行うツールを実装した。

4. 予測の評価と考察

予測精度の評価は式(2)に示す平均絶対パーセント誤差(MAPE)を用いた。

$$MAPE = \frac{\sum |(y_t - \hat{y}_t) / y_t|}{n} \times 100 \quad (y_t \neq 0) \quad (2)$$

y_t : 実測値 \hat{y}_t : 予測値 n : データ数

表1: データ詳細

対象	8階建てオフィスビル 5階
期間	2013年4月1日から2015年3月31日
場合分け候補	<ul style="list-style-type: none"> ・月 ・曜日 ・時間 ・最高気温 ・就業日判定(就業日, 休業日) ・季節区分(冷房期, 中間期, 暖房期) ・継続時間(始業時から経過した時間) ・在室人数
説明変数候補	<ul style="list-style-type: none"> ・月 ・曜日 ・時間 ・気温 ・就業日判定(就業日, 休業日) ・季節区分(冷房期, 中間期, 暖房期) ・継続時間(始業時から経過した時間) ・在室人数

本研究で使用するデータの詳細と2項で選出した場合分け・説明変数候補を表1に示す。

表1に示したデータのうち2013年4月1日から2014年3月31日までのデータを用いて予測モデルを作成し、2014年4月1日から2015年3月31日までのデータを用いて空調機器の電力需給を予測した。

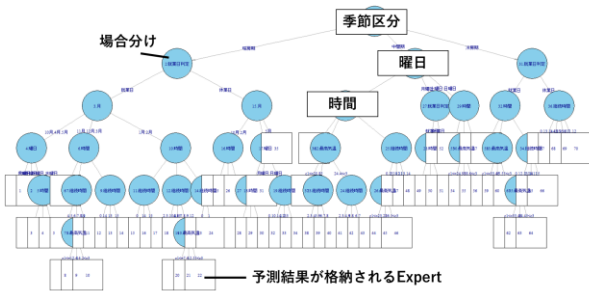


図3: 提案手法による電力需要予測結果出力

提案手法による電力需要予測結果を図3に示す。青い丸内に使用された場合分け条件が記載されており、決定木での葉に当たるエキスパートに予測結果が格納されている。電力需要制御は通常就業日に実施されるため、就業日中のMAPEを計測したところ、勾配ブースティング木による非線形手法では21.1%であったのに対し、提案手法では22.7%とほぼ同等の高い精度を得た。

しかし、電力需要制御を行うためには、この予測結果から空間特性を抽出する必要がある。

図3から得られたエキスパートの1つが持つ予測式の標準化偏回帰係数をレーダーチャートにより可視化したものを図4に示す。

レーダーチャートでは、消費電力量の増加に負の影響を与える説明変数の係数は凹になり、正の影響を与える係数は凸になるように可視化する。




図4: 空間特性の可視化

図4では、暖房期である11, 12, 2月の就業日で8~20時の間の予測結果を持つ。継続時間が7時間と8時間というのは16:00, 17:00に該当するので終業時間近辺の時間帯を表す。

図4より、空間特性として気温と在室人数、終業時間近辺の時間帯が相当し、暖房期の就業日は、終業近辺の時間帯に、帰宅などにより在室人数が変化し、室内温度が低下したため消費電力量が増加したと解釈が可能になる。

この事例での電力需要制御の例として、事前に部屋を暖める予熱制御を行うことで16:00, 17:00に起こるピークを小さくすることができる。

このように、提案手法を用い、予測結果を解釈可能であり、制御に繋げることが可能となる。

5. まとめと今後の展開

有識者たちにより定義されたブロック定義図を用いて説明変数候補から最適な場合分けと説明変数の選定を行う異種混合学習技術を用いたツールを開発した。また、説明変数で空間特性が解釈可能な線形式と本ツールを用いて電力需要予測を行い、有用な制御を提示できることを示した。

今後は、局所最適に陥るのを防ぐために因子化情報量基準(FIC)[2]などのように場合分けの評価を行う評価指標を導入する。また、ブロック定義図に記載されているが抽出できなかった説明変数を含めた予測や他用途のビルでの予測を行う。

参考文献

[1] 藤巻遼平, 森永聡, 江藤力, 本橋洋介, and 菅野亨太, “異種混合学習技術とビッグデータ分析ソリューションの研究開発,” 第29回フジサンケイビジネスアイ賞, 2015.

[2] R. Eto, R. Fujimaki, S. Morinaga, and H. Tamano, “Fully-Automatic Bayesian Piecewise Sparse Linear Models,” *Proc. AISTATS*, vol. 33, pp. 238–246, 2014