

デマンドレスポンスのためのスマートメータ情報による家庭プロフィール作成手法の提案

池田 伸太郎[†] 西 宏章[†]
慶應義塾大学 理工学研究科[†]

1. はじめに

スマートメータの導入に伴い、数十分単位の細かい粒度の電力使用データが取得可能になり、そのデータから作成される家庭ごとのプロフィール情報の応用的利用の研究が行われている。

中でも、デマンドレスポンス運用への応用が期待されており、これによって電力市場価格の急激な増加を起こさずに電力の需給バランスを調整することが可能となる。また我が国では電力自由化によって電力会社は今後増加していき、デマンドレスポンスの面でも顧客として最適な家庭を選択する必要がある。

本研究では、デマンドレスポンスサービスにおいて顧客を最適な電力会社に割り当てるための家庭プロフィール作成手法を提案する。提案手法では、ニューラルネットワークの一種である Sparse Coding を採用した。また家庭を各電力会社の顧客として割り当てることを想定し、クラスタリング手法を用いることで家庭をグループ化した。本研究では評価基準として、デマンドレスポンス効果が期待される空調電力の利用誤差率を採用し、提案手法では処理を加えない方法に対し約 24%誤差率が低いことを確認した。

2. 提案手法

本研究では、デマンドレスポンスサービスのための家庭プロフィール作成手法を提案する。また、プロフィール作成後、そのプロフィールに基づいてクラスタリングを行い家庭のグループ作成する。家庭プロフィール作成に、Sparse Coding と呼ばれる手法を利用した。

Sparse Coding は、ニューラルネットワークに属する教師なし機械学習手法であり、主に画像処理の分野で、少ない情報量から画像を修復、復元する際に用いられることが多い[1]。本研究で Sparse Coding を採用した理由は次の通りである。まず、教師なし学習であるため教師あり学習とは異なり、付加的なラベルデータが不要であるためスマートメータによるデータのみで学習を行うことができる。次に、時系列電力量の学習におい




図 1 Sparse Coding の概要図

て他の学習方法に対してスマートメータにおける 15 分や 30 分間隔という比較的長間隔においても特徴の抽出に優れている。したがって、需要供給の同時同量に用いる予測にも適していると考えられる[2]。

Sparse Coding の概要図を図 1 に示した。図では X, B, A とあり、それぞれが入力集合、学習モデル、係数集合を示している。本研究では X をスマートメータから得られる電力データとしたときの学習で作成される B を家庭プロフィールと定義しこれを用いてクラスタリングを行う。

2.1 プロフィール作成

Sparse Coding を家電の電力使用からその推定に应用している研究[3]の中で用いられている式を利用し、家庭プロフィールを作成する。

$$\underset{(A, B)}{\text{minimize}} \frac{1}{2} \|X - BA\|_F^2 + \lambda \sum_{i=1, k=1}^{l_{\text{train}}, n} |a_{i,k}|$$

X は入力データである総電力使用データであり、時刻数 (15 分間隔ならば 96 個) と日数分を示した行列である。B は作成目的の家庭プロフィールもとい学習モデルであり、時刻数と基底数と呼ばれる任意に設定できる値の行列で表される。A は係数集合であり日数と基底数の行列である。λ は二項目の係数であり、これも任意に設定ができる。第二項は、機会学習における過学習を防ぐための項である。また、α はある家庭、a は A の行列の成分、l_{train} は学習する日数、n は基底数を示す。この式において B と A を交互に更新し、式の値が収束したときの B を家庭プロフィールとして決定する。

2.2 家庭クラスタリング

Household profile for demand response services from smart meter data

[†] Shintaro Ikeda, Hiroaki Nishi, Dept. of Syst. Design, Keio University, Yokohama

本研究では、作成した家庭プロファイルを元に電力会社顧客としての家庭グループを作成し、デマンドレスポンス運用を行いやすくすること目標とする。本研究では、プロファイル作成で得られたモデル行列をもとにグループを作成する対象の地域内の家庭全体の時系列総電力を復元し、その値から階層的クラスタリングを用いてグループを生成する。はじめに、以下の式にしたがって、復元電力行列を生成する。

$$\hat{A}_{\alpha,\beta} = \arg \min \|X_{\beta} - B_{\alpha}A_{\alpha,\beta}\|_F^2 + \lambda \sum_{i=1,k=1}^{l_{test},n} |a_{i,k}|$$

$$\hat{X}_{\alpha,\beta} = B_{\alpha}\hat{A}_{\alpha,\beta}$$

上記の式において、 β は α と異なる家庭を示しており、また l_{test} は復元対象日数である。この式では作成された B_{α} から \hat{A} を求めその \hat{A} と B_{α} から復元電力行列 \hat{X} を生成し、その地域内すべての家庭に対して \hat{X} を求める。さらに、その和を地域内の評価量とする。以下に評価量を作成する式を示す。Eがその復元行列と実際の電力データ行列の二乗誤差であり、その値から評価量を求める。

$$E(\alpha, \beta) = \|X_{\beta} - \hat{X}_{\alpha,\beta}\|_F^2$$

$$e(\alpha) = \sum_i E(\alpha, i) \quad (i \in \text{universal set})$$

さらに、家庭ごとに得られた評価量 e を用いてクラスタリングを行うため、階層的クラスタリングを用いる。この手法はクラスタリング処理後に任意にクラスタ数を確定できるため、家庭グループ作成目的に合致する階層的クラスタリングのアルゴリズムには一般的に用いられるウォーク距離を採用した。

2.3 データ正規化

本研究では、家庭の居住者の行動傾向の特徴をより抽出しやすくすることを目的に定常化電力削減も試みた。家庭ごとの定常的に利用されている電力を次式で定義し、この電力分を切り落とした場合でも入力データを作成し比較検討を行う。

$$x_{fixed} = \frac{1}{N} \sum_{r=1}^N \min(x_{1,r}, x_{2,r}, \dots, x_{m,r})$$

3 評価結果

本研究では、宮城県栗原市で行った HMES 実験の対象家庭 10 件分の電力データを用いた。時系列電力データは 15 分間隔とし、評価に用いた期間は 2014 年 8 月の 31 日分である。評価として、本研究では空調電力の利用傾向のグルーピングの精度とした。空調電力は、制御のしやすさ、ピーク時における占有電力量の大きさから、最も削減、ピークシフトの効果が期待でき、デマンドレスポンスサービスの対象として相応しいと考えられる。また、提案手法に対する比較として、総電力量の平均値を評価量した階層的クラスタリ

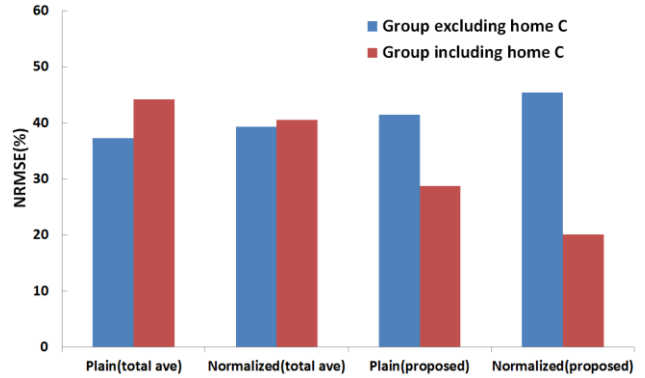


図 2 各アプローチの空調電力使用誤差率

ングをした方法を採用した。評価においては 10 軒の家庭(A~J)において 3 番目の家庭 C が階層的クラスタリングを行い、グループを 4 つに区切ったときに 3 軒分の家庭グループに属する家庭であったということから家庭 C を基準の家庭とした。評価量では以下の式を用いた。

$$NRMSE_{\alpha} = \frac{\sqrt{\frac{1}{M} \sum_m (y_{m,\alpha} - y_{m,C})^2}}{y_{C,max} - y_{C,min}} \times 100\%$$

$NRMSE$ は標準化された二乗誤差であり、空調電力の使用誤差率を意味する。 y は空調電力量であり、 m は時刻、 M は全時刻数($M = 96 \times 31$)である。この値を評価量にして示したものが図 2 であり、図 2 より提案手法(proposed)の方が比較手法(total ave)よりもグループ内の $NRMSE$ が約 24%低く、また、提案手法では定常化電力を削減した場合(Normalized)の方がそうでない場合(Plain)よりも $NRMSE$ が約 9%低いことを示した。

4 結論

Sparse Coding を用いて デマンドレスポンスサービスのための家庭プロファイル作成手法とその利用方法を提案した。評価として、作成したグループ内の空調電力使用の誤差率を利用し、提案手法では処理を加えない方法に対し約 24%誤差率が低いことを確認した。

謝辞 本研究は、セコム科学技術振興財団研究助成、科研費基盤 B(24360230)(25280033)、国交省住宅・建築物技術高度化の一環としてなされた。

参考文献

- [1] Mairal, J., Bach, F., Ponce, J., & Sapiro, G. (2009). Online dictionary learning for sparse coding. Proceedings of the 26th International Conference on Machine Learning, 1-8.
- [2] 西宏章, “スマートコミュニティにおけるインフラストラクチャとサービス,” 電子情報通信学会誌 Vol. 98, No. 2, pp. 112-117, 2015
- [3] Kolter, J. Z., Batra, S., & Ng, A. Y. (2010). Energy Disaggregation via Discriminative Sparse Coding. Advances in Neural Information Processing Systems, 1153-1161.