

30 分電力値を用いた各戸・地域電力需要予測

坂井亮文^{†1} 久代紀之^{†1} 樋熊利康^{†2}

概要： 現在日本では電力の安定供給を目的としてデマンドレスポンス（以下 DR）の導入が検討されている。DR で生じる顧客の節電への負担を減らすことができる制御手法は実際に DR を導入するためには不可欠である。その制御を実現するためには電力需要予測モデルを構築する必要がある。本論文ではスマートメータで収集された 30 分電力値を用いて需要家個々の電力需要予測モデルの構築を目指す。

キーワード： 知識発見, 回帰, 社会基盤としての情報システム

Electric power demand prediction on every 30 minute meter reading value for residential and community

AKIFUMI SAKAI^{†1} NORIYUKI KUSHIRO^{†1} TOSHIYASU HIGUMA^{†2}

Abstract: There is a growing interest to introducing Demand Response (DR) into buildings and residences for realizing stability of power distribution. A sophisticated control method, which can reduce customers' inconveniences induced by the DR, is essential for penetrating the DR in the real market. Furthermore, an energy prediction model is required for designing the above control methods. In this paper, we tried to develop an electric power demand prediction model for each residence, which described in liner regression model, on every 30 minute meter reading data collected by smart meter.

Keywords: Knowledge discovery, Regression, Information systems as social infrastructures

1. はじめに

1.1 研究背景

現在、日本ではデマンドレスポンスの導入が検討されている。デマンドレスポンスとは、ピーク時の需要を抑制することで、一日の電力消費を平滑化する仕組みのことで電力供給を安定させることを目的としている。既存の電力供給と大きく異なる点は電力需給制御に電力会社のみならず、企業や一般家庭といった需要家が参加することである。デマンドレスポンスでは、ピーク需要時需要家に節電を行ってもらうことで需要を抑制する。現在このデマンドレスポンスの手法として TOU（Time of Use Rate）や CPP（Critical Peak Price）などがある。これらの手法では、電力会社はピークが予測される時間帯の電力料金を割高に設定することで需要家にピーク時の節電を促す。需要家は節電を行うことに対して経済的な報酬を得ることができるが一般家庭では経済的な合理性だけでは節電に参加をしないことも多い[1]。一般家庭における需要家の節電への不参加の原因として具体的な節電方法がわからないことや節電によって生じる不便などが考えられる。このような需要家の負担を軽減し、節電への参加を促す支援が求められている。そこで本研究ではこれらの支援に必要となる 30 分電力値を用い、一般家庭の電力需要予測モデルを構築する。

1.2 研究のアプローチ

本研究では、一般家庭向けの家庭の電力消費特性を考慮した制御を目指す。家庭の電力消費特性とは、こういった要因が電力消費に正もしくは負の影響を与えているのかということであり、例えば、生活者のライフパターンに応じたある時間帯の電力消費が大きいなどである。特性を知ることができれば、節電の参加を促す支援が可能になる。そこで以下のようなアプローチを取ることで家庭の電力消費特性を考慮した制御を実現する。

1. 各戸需要予測モデルの構築
2. 地域需要予測モデルの構築
3. グループ単位の制御手法の提案とアドバイスの生成

本研究では、予測モデルを構築することにより、家庭の電力消費特性をパラメータとして抽出する。またモデル構築によって得たパラメータを用いて似通った特徴を持つ家庭をグループ化することでグループ単位への制御を可能にする。本論文では、各戸需要予測モデルの構築に関してまでを述べ、どのように家庭の電力消費特性を抽出するかを示す。

2. 各戸需要予測モデルの構築

まず初めに、各家庭の予測モデルを構築に当たって家庭ごとのデータの収集が必要である。本研究では、一般家庭

^{†1} 九州工業大学
Kyushu Institute of Technology

^{†2} (株)三菱電機
Mitsubishi Electric

への設置が進められているスマートメータで収集されているデータを用いる。スマートメータでは、30分毎に家庭全体の30分電力値が記録されている。30分電力値より家庭の電力消費特性を抽出する手法として、線形モデルを用いた予測モデルを構築する。予測モデルにおいてある目的変数を精度よく予測するためには、適切に目的変数に影響を与える要因を説明変数に設定する必要がある。そして、それらの要因の影響はモデル式の回帰係数によって表現されるため電力消費特性をモデル式の回帰係数で表現することができる。つまり、精度の高いモデルを構築することは正確に電力消費に関連する要因を明らかにすることと同義となる。線形モデルは一般的に以下のような式(1)で示される。

$$y = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n + \beta \quad (1)$$

y:目的変数 x_n :説明変数 α_n :回帰係数 β :切片

線形モデルを選んだ理由として目的変数と説明変数の関係性が直感的にわかりやすいという点がある。例えば、気温 x_1 に対して α_1 が推定され、 α_1 の大小や正負によって気温と消費の関係を解釈できる。一方で線形モデルの欠点として予測精度の悪さがあげられる。この予測精度の悪さは説明変数の不足や組み合わせ、その他に説明変数と目的変数の関係に冷房と暖房など明確な場合分けが必要なデータなどが原因として考えられる。適切なモデルを生成するために以下が必要になる。

- ① 説明変数、場合分け条件になり得る要因の抽出
- ② 最適な説明変数の選択

①の説明変数、場合分け条件となる要因の抽出についてはブレインストーミングおよびKJ法、拡張ゴールグラフ[2]を用いたアイデア会議によって候補を抽出する。具体的な手順については2.1項に述べる。②の線形モデルの説明変数の最適化の手法として、既存研究の異種混合学習[3][4]を適用する。本手法においては下記の三つの手順を踏むことでモデルの最適化を行っている。

- i.データの場合わけ条件の最適化
- ii.説明変数の組み合わせの最適化
- iii.不要な予測モデルの削除

これらの手順は以下の図1のように表される。最適化をブレインストーミング、KJ法により抽出された説明変数からデータの場合わけが必要な説明変数を決定し、階層的クラスター分析を用いてデータの場合分けを行う。そして、場合分けされた各データそれぞれにモデルを構築する。

2.1 説明変数と場合分け条件の抽出

予測モデルの構築では、目的変数に影響を与える要因をみれなく説明変数として加えることが重要である。しかし、例えば電力消費に影響を与える要因を考えた場合、時間や在否、曜日など様々な要因が複雑に絡まっていることがわかる。一般的にモデル構築において説明変数やデータの場合

分けは専門家の試行錯誤によって行われ、一定の方法で




図1 モデル最適化

Figure 1 the optimization of model

行われない。本研究では、体系的に説明変数と場合分け条件の抽出を行うために拡張ゴールグラフ[2]を用いた。拡張ゴールグラフは要求分析手法の一つであり、ゴールを最上位に配置し、ゴールを達成するための機能とその機能を実現する手段を階層的に記述し、情報を整理する手法である。電力消費は様々な家電機器の組み合わせによって消費量が決まる。家電機器の使い方や使用条件は機器毎に異なる。この使用条件の違いは場合分け条件の候補になりえる。また説明変数は使用条件をより具体的に数値化することで得られる。拡張ゴールグラフでは、使い方や使用条件の視点と具体的な数値化を階層的に表示することで、もれなく場合分け条件や説明変数の候補を抽出できると考えた。具体的な手順は以下の通りである。

- I.ブレインストーミングによる家電機器の抽出
- II.KJ法による使用法を視点としたグループ化
- III.拡張ゴールグラフを用いた視点の数値化




図2 説明変数抽出方法概要

Figure 2 Discovery of explanatory variable

電力消費は様々な家電機器の組み合わせである。そのため一般的に家庭で使用される家電機器をみれなく抽出することが重要である。Iのブレインストーミングでは様々な意見を取り入れることができ、もれを少なくすることがで

きる．Ⅱでは KJ 法をⅠで抽出された家電機器を何に影響されて使用するか，どのタイミングで使うかを視点にグループ化をする．発見された視点によりどのような規則性を持つのかを明確にすることができる．ⅢではⅠ，Ⅱの結果を拡張ゴールグラフにより階層的に整理し，視点を数値，属性に具体化する．加えて具体化されたデータの取得方法を考察し，使用可能を確認した．

以下の図 3 は実際にⅠからⅢの手順でアイデア会議を行ったときの拡張ゴールグラフとその結果を表 1 にまとめたものである．




図 3 拡張ゴールグラフによる抽出結果
Figure 3 Result of Extended Goal Graph

表 1 説明変数の抽出結果
Table 1 Result of the factor extraction

クラスタリング視点	電力機器	説明変数
季節、気温	こたつ、エアコン、ホットカーペット、電気ストーブ、扇風機、便座、床暖房	日射 外気温 室温 最高気温 最低気温
天気	除湿機、乾燥機、洗濯機	天気 風力 湿度
定期的(常時)	冷蔵庫、換気扇、温水器、テレビ、電気ストーブ、照明、便座、ビデオ	家、部材 職業 一日あたりの使用時間
曜日、人がいる時間、時刻	ジャー炊飯器、食器洗浄機	家族構成 平均利用時間 時刻
使う人、使用時間の長さ、ライフイベント	ドライヤー、IHクッキングヒーター、掃除機、電機ポット、電子レンジ	曜日 在否 単位時間あたりの電力消費

結果として 17 の説明変数，場合分け条件の候補を抽出することができた．また拡張ゴールグラフ作成時に抽出したデータソースを元に実際に使用可能な候補を絞り込んだ．結果，外気温，最高気温，最低気温，日照時間，時刻，曜日の六つの候補をモデル構築に採用することを決定した．

2.2 データの場合分け最適化

線形モデルでは予測式は単純な線形の形で表すことができる．しかし，単純な線形であるために異なる相関を持つ要因，説明変数を正確に表現できないという課題がある．例えば，気温と消費電力の関係があてはまる．以下の図 4

は 30 分電力値と気温を図示したものである．図 4 より気温の上昇に対して正の相関を持つデータと負の相関を持つデータが混在していることがわかる．




図 4 消費電力と外気温の関係

Figure 4 Relations of power and temperature

このようなデータに対し，異種混合学習[3][4]ではデータの場合分けを行い，場合分けされたデータ毎にモデルを構築することで線形モデルの精度を向上させている．本研究では，異種混合学習をベースに階層的クラスター分析を用いることで場合分けを行う．階層的クラスター分析では，樹形図の生成により場合分け数の変更も非常に容易に行うことができるという利点もある．以下の図 5 が階層的クラスター分析によって作成される樹形図である．




図 5 階層的クラスター分析結果例

Figure 5 the example of Clustering

場合分けを行う対象として 2.1 項で挙げた六つの候補から曜日と時刻，気温を決定した．理由とそれぞれの具体的な場合分け手法は 2.2.1 及び 2.2.2 で述べる．本研究では場合分けを図 6 の形で繰り返し行い，気温，時刻，曜日の順で場合分けを行うこととした．




図6 場合分け例

Figure 6 the example of dividing

2.2.1 気温の場合分け

気温と消費電力の関係は図4から複数の相関関係が含まれていると考えられる。表1より気温が影響を与える家電機器はエアコンなどの空調であることがわかる。空調機器はその使用が気温によって大きく異なる。冷房、暖房、未使用の場合が考えられ、それぞれ相関も異なると考えられる。冷房では正の相関、暖房では負の相関、未使用の場合は相関がないと推測できる。気温の場合分けでは、これらの相関が含まれているかを調査する必要がある。気温の場合分けでは以下の図7の手順で場合分けの数と場合分けの基準となる気温を決定する。




図7 気温場合分けの手順

Figure 7 Procedure of temperature division

本研究では、初めに一日の総消費電力量と最高気温を用いて階層クラスター分析を行い、三つのクラスターにデータを分割する。三つのクラスターについて相関係数を求め、データに含まれている相関を明らかにする。相関係数の絶対値が0.4以上のものを相関ありとして判定する。相関係数とクラスター毎の平均最高気温を元に空調機器の使用状況を推定する。相関の種類が二つしか存在しない場合は相関係数を基準にデータを再分割する。空調機器の使用は気温によって変化すると考えられるが、階層的クラスター分析ではクラスター境界では別々のクラスターのデータが混在する場合がある。そのため境界となる気温を以下の式(2)

を用いて場合分けの基準を明確にする。

$$t = \frac{(d_1 \text{の最高気温}) + (d_2 \text{の最低気温})}{2} \quad (2)$$

$d_{1,2}$: クラスター(ただし d_1 の平均気温 < d_2 の平均気温)

これにより複数の相関を分割し、線形モデルの精度を向上させることができる。

2.2.2 時刻及び曜日の場合分け

時刻と曜日は、家電機器の使用における視点において習慣や生活の規則性を具体的にしたものである。時刻で行う場合分けは在否である。不在の場合は気温などその他の要因の影響もほとんど受けない。曜日では休日と平日を例に在宅時間の差によって消費が大きく異なる。二つの候補は在否、在宅時間の長短の点から二つに場合分けを行う。時刻および曜日は質的な変数であるため各属性に平均消費電力を求め、階層的クラスター分析によって場合分けを行う。

2.3 説明変数の最適化

場合分けを行った結果、分割されたデータ毎にモデルを構築する。各データはそれぞれ相関が異なり、必要な説明変数も異なる。よって各データに対して最も適した説明変数の組み合わせを見つける必要がある。異種混合学習[3][4]では全ての組み合わせについてモデルを作成し、場合分けや説明変数の複雑さと予測精度のよさを包括的に評価するために因子化情報量基準を用いている。本研究ではモデルが如何に消費特性を表すことができているかが重要である。消費特性が表すことができているとは、すなわち予測精度の高さであると考え、説明変数の最適化は予測精度の評価基準の一つである絶対パーセント誤差(MAPE)を用いる。以下の式(3)で MAPE は求められる。

$$MAPE = \frac{\sum |y_t - \hat{y}_t| / y_t}{n} \times 100 \quad (3)$$

y_t : 観測値, $\hat{y}_t$: 予測値, n : データ数

候補である6つの要因が独立となる説明変数の組み合わせのモデルを全て作成し、最も MAPE の値が小さいものを最適な説明変数の組み合わせとして採用した。

2.4 モデルの作成と評価

ある家庭のデータを用いてモデルの構築とその精度と消費特性の抽出具合の評価を行った。今回用いたデータの詳細を以下の表2に示す。

表2 実験データ詳細

Table 2 Detail of experiment data

期間	2014/07/01~2015/6/30
内容	30分電力値, 気象データ

表2のデータと2.1項で抽出した6つの説明変数の候補を用いて場合分けの最適化を行った結果を以下の図8に示す。




図 8 モデルの全体とデータの場合わけ結果

Figure 8 Whole model and Result of data division

図 8 より A~H の 8 つに分割され、それぞれのデータに説明変数の最適化を行った結果の MAPE を以下の表 3 に示す。全体は A~H のモデルを切り替えながら予測を行った場合の評価である。

表 3 各モデルの MAPE

Table 3 MAPE for each model

全体	A	B	C	D
27.02%	22.99%	21.69%	22.85%	26.97%
E	F	G	H	
25.57%	28.04%	30.91%	30.90%	

MAPE の値から予測モデルとしての精度は決して良いモデルとは言えないことがわかった。精度の悪さの原因として 2.1 項における候補の抽出不足や使用できたデータの少なさが挙げられる。MAPE は説明変数の最適化の基準として用いたが、予測精度は消費電力をモデルの説明変数でどの程度表しているかの指標にもなると考えている。説明変数やデータの場合分け不足が考えられるが、このモデルの回帰係数から電力消費特性が抽出できるかを確認した。以下の表は図 8 と表 3 における E にあてはまるモデルの回帰係数を示したものである。

表 4 モデル E の回帰係数

Table 4 Coefficients of model E

(Intercept)	-0.05737	time19:30	-0.02904
time00:30	0.000952	time20:00	-0.02477
time01:00	-0.01181	time20:30	-0.03617
time01:30	-0.02251	time21:00	-0.03457
time06:30	-0.00395	time21:30	-0.02825
time07:00	-0.00157	time22:00	-0.02191
time07:30	-0.06404	time22:30	0.008594
time17:30	-0.08689	time23:00	0.006405
time18:00	-0.07654	time23:30	0.021558
time18:30	-0.06475	temperature	0.026804
time19:00	-0.0535		

表 4 の回帰係数から時刻の 17:30~23:30 を表すものを以下の図 7 に示す。




図 9 17:30~23:30 までの回帰係数

Figure 9 Coefficients of time from 17:30 to 23:30

図 9 より 17:30 から電力消費が増加する傾向にあることがわかる。また気温の回帰係数とベースとなる切片の大きさを比較すると気温の回帰係数が非常に大きいことがわかり、気温の影響を非常に受けやすいことも推察することができる。回帰係数から消費特性を抽出できることがわかった。一方で予測精度の低さから一部の回帰係数では p 値が高く統計的に有意ではない結果が出ている。

3. まとめと今後

本論文では、30 分電力値により各戸の需要予測モデルの構築に関して述べた。この結果として異種混合学習をベースとした手法を用いてモデルを構築し、回帰係数から家庭の電力消費特性を抽出できることがわかった。しかし、予測精度の低さや一部の回帰係数が p 値を満たさないという課題があることもわかった。データの場合分けの最適化において場合分けの不足の確認などモデルの最適化について改善する必要がある。

今後として抽出された消費特性を元に各家庭を分類していくために特性の比較方法やモデルの拡張方法について検討していく。

謝辞 本研究の一部は、JSTCREST および科研費基盤研究(A) 16H01836 の支援を受けて実施されたものです。

参考文献

- [1] 服部徹, 戸田直樹.(2011).米国における家庭用デマンドレスポンス・プログラムの現状と課題-パイロットプログラムの評価と本格導入における課題-.電力中央研究所報告
- [2] Noriyuki Kushiro, Takuro Shimizu and Tatsuya Ehira: Requirements Elicitation with Extended Goal Graph, 20th International Conference on Knowledge Based and Intelligent Information and Engineering System, KES2016, Sep.2016 York, United Kingdom. Procedia Computer Science (2016) pp. 1691-1700, DOI information: 10.1016/j.procs.2016.08.217
- [3] 藤巻遼平, 森永聡, 江藤力, 本橋洋介, 菅野亨太. (2015). 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. 独創性を拓く 先端技術大賞, 第 29 回フジサンケイビジネスアイ賞.
- [4] 森永聡, 藤巻遼平. (2014). 異種混合学習技術によるビッグデータ分析ビジネス(ビッグデータ特別セッション). 日本計算機統計学会大会論文集 28, 59-60.