

# 家庭用電気機器オン・オフ動作判定への サポートベクターマシンの適用

小野田 崇, 中野 幸夫

## 1. はじめに

需要家の有する電気機器の構成や使用実態に関する情報は、Demand Side Management 効果の評価、潜在需要の推定、需要変化の予測、負荷率悪化の要因分析、きめ細かな季時別料金システムの構築、需要家への各種的確なサービスの提供等を行なう上で必要不可欠なものの一つである。需要家における電力量の使用実態に関する測定はロードサーベイと呼ばれ、需要家の給電線の入口付近にセンサを設置して総負荷曲線を測定する場合と、下流に接続されている電気機器に直接センサを設置して、各電気機器ごとのオン・オフの動作状態や負荷曲線を測定する場合とがある。

従来、電気機器ごとの使用実態を測定するためには、需要家の中に立ち入って電気機器や給電回路にセンサやデータ収集装置を取り付ける必要があった。この測定方式は、需要家内に立ち入ることから侵入型 (Intrusive) と呼ばれている。この侵入型の測定装置は、既にいくつか開発されている [1, 2, 3]。しかし、侵入型の測定方式では、需要家内にセンサやデータ収集装置を設置する作業や工事が必要となり、コスト高となる。さらに、工事やデータ収集に関連して需要家に負担を強いる等の問題点も多い。このため、工事やコスト、需要家への負担等を極力小さくした方法の開発が望まれる。つまり、需要家内へ侵入することなく、各電気機器の、あるいは用途ごとの電気の使用実態を測定する方法の開発が望まれる。この方式は、需要家内に立ち入らないことから非侵入型 (Non-Intrusive) と呼ばれ、図 1 に示すように、需要家の給電線入口付

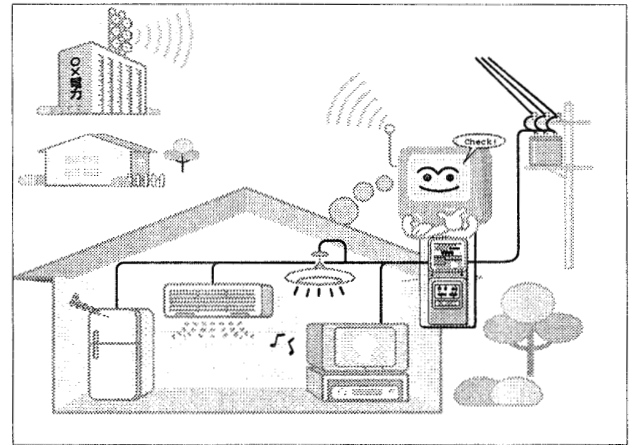


図 1: 非侵入型モニタリングシステム

近での測定で得られる情報のみから、需要家内部の電気機器の動作状態を推定しようとするものである。

米国の Electric Power Research Institute では、Massachusetts Institute of Technology で開発したアルゴリズムに基づいて、需要家の給電線入口付近で計測した総負荷電力を各電気機器の消費電力に弁別分離する非侵入型の装置を開発している [4, 5]。このアルゴリズムでは、電気機器のオン・オフの動作を総負荷電力におけるステップ状の時間変化として捉え、個別電気機器の定格消費電力と力率からオンあるいはオフした機器の特定を行なっている。しかしながら、昨今普及の著しいインバータ回路を有する電気機器 (以下、インバータ機器とする) では、消費電力の時間的推移が必ずしもステップ状ではなく、穏やかに変動したり、あるいは不規則に変動するため、このアルゴリズムではインバータ機器とインバータを有さない機器 (以下、ノンインバータ機器とする) が混在する場合、動作変化を引き起こした電気機器の特定は難しい。

このような背景に基づき、総負荷電流を用いて、下流に接続されている個別電気機器の動作状態を同定

おのだ たかし (財) 電力中央研究所 情報研究所  
なかの ゆきお (財) 電力中央研究所  
需要家システム部  
〒 201-8511 狛江市岩戸北 2-11-1

するアルゴリズムに、Support Vector Machine(以下、SVM とする)を適用することを検討する。

第2章では、総負荷電流に関する情報のみから個別電気機器の動作状態を推定するためのデータ測定方法について述べる。第3章では、第2章で述べる測定方法で得られたデータを入力パターンとし、個別電気機器の動作状態(オンまたはオフ)の推定を行なうために適用したSVMについて簡単に紹介する。第4章で、これらの方法をインバータ、ノンインバータ機器の混在する場合の電気機器の動作状態推定に適用した数値実験結果について報告し、まとめと今後の課題について第5章で述べる。

## 2. 家庭内電気機器動作状態推定問題とデータ測定方法

### 2.1 家庭内電気機器動作状態推定問題

一般家庭の屋内配線を簡略化して表現すると家庭内の電気機器の接続状況は図2のように模擬的に表すことができる。図2の左側にある電源は商用の系統を表し、PTとCTは家庭への給電線入口付近に設置を想定している電圧センサと電流センサである。ここで、A~Fは接続されている電気機器を表す。今回測定で考慮した機器を表1に示す。

インバータ機器、ノンインバータ機器の混在する一般的な家庭内の電気機器の動作状態を精度良く推定するため、電気機器が動作中に発生する高調波電流とその位相に注目した。図3、4に代表的な電気機器としてインバータエアコンと白熱灯の高調波電流とその位相を各次数ごとに表したグラフを示す。これらの

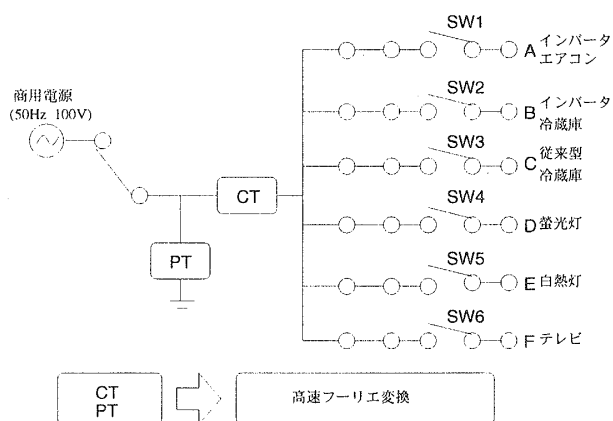


図2: 家庭内の電気機器の接続状況の一例

表1: 考慮した電気機器

番号	電気機器
1	インバータエアコン1
2	インバータエアコン2
3	扇風機
4	白熱灯
5	蛍光灯
6	インバータ蛍光灯
7	テレビ1
8	テレビ2
9	電気ポット
10	冷蔵庫

図から明らかなように、電気機器ごとに高調波電流とその位相のパターン(以下、高調波成分パターンという)は異なる様相を示す。また、数種の電気機器を組み合わせて動作した場合の高調波成分パターンも、機器の組み合わせに固有の様相を示す。つまり、高調波成分パターンは電気機器あるいは動作している電気機器の組み合わせに対して固有のものであり、動作している機器類の状態が同じであるなら(ただし、計測誤差や流入高調波の影響は無視する)類似した高調波成分パターンとなる。

家庭内電気機器の動作状態に依存して変化する総負荷電流の高調波成分パターンは、給電線の家庭内への入口付近でPT、CTによって計測した電流値、電圧値を高調波測定器に取り込み、高速フーリエ変換する




図3: エアコンの高調波成分パターン




図 4: 白熱灯の高調波成分パターン

ことで得ることができる。

以上より、家庭内電気機器動作状態推定問題は、家庭の外で観測できる総負荷電流の高調波成分パターンに基づき家庭内で動作している電気機器を分類する問題であると考えることができる。

## 2.2 データ測定方法

図 2 に示した家庭内電気機器の接続模擬回路を用いて、家庭内電気機器の動作状態を推定するモデルを作成(学習)するための総負荷電流における高調波成分パターンを収集した。データ測定は以下の手順により行なった。

1. 図 2 中にある  $SW_i$  はスイッチを表しており、これらのスイッチを適宜切替えることで表 1 に示した測定する電気機器の組合せを変える。
2. 図 2 中 PT, CT により電流値と電圧値を測定する。
3. 上記給電線の家庭内への入口付近で PT, CT によって計測した電流値、電圧値を高調波測定器に取り込み、高速フーリエ変換することで、家庭内電気機器の動作状態に依存して変化する総負荷電流の高調波成分パターンを得る。

個別電気機器動作状態推定モデルを作成するための入力データとしては、観測した高調波成分パターンの第 1 次～第 13 次の奇数次高調波電流とその位相を利用した [6, 7]。




図 5: 電気機器動作状態推定システムの概略

## 3. 電気機器動作状態推定システム

図 5 に SVM を用いた電気機器動作状態推定システムの概略図を示す。本章では、電気機器動作状態推定システムに適用した SVM について簡単に紹介する。

SVM の概念を図 6 に示す。図 6 の左の図は 2 次元の観測空間にデータが観測された様子を表している。ここで、白丸 (○) がある電気機器はオンの状態を表し、黒丸 (●) がオフとして、この白丸と黒丸を分類したいとする。しかし、この観測空間では白丸と黒丸を線形識別関数を用いて分類することができない。そこで、観測データを観測空間と非線形の関係にある特徴空間に表現し直す。それを示したのが図 6 の中央の図である。図 6 の中央では特徴空間が 3 次元空間で表現されているが、実際は特徴空間が 3 次元空間である必然性はない。観測空間を特徴空間へ写像することにより線形の判別をできるようにし、特徴空間で線形の識別関数を推定する。SVM では特徴空間での線形識別関数の生成に Vapnik の提唱する最適超平面分類法を用いる [8]。

また、観測空間から特徴空間へ観測データを表現し直す際に、SVM ではカーネル関数を用いる。このカーネル関数通じて観測データを表現し直すことによって、観測空間上のデータを高次元の特徴空間上へマッピングすることが可能となる。最も一般的に使用されるカーネル関数は次式で表現される Radial Basis カーネル関数 (以下、RBF カーネルと記述)[8, 9, 10] である。

$$k(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right). \quad (1)$$

このように、一般的な非線形 SVM は以下の 2 つを特徴とするパターン認識手法である。

1. 観測データを非線形写像を用いて高次元特徴空間へマッピング。




図 6: Support Vector Machine の概念図

2. Vapnik の提唱する最適超平面分類法を用いて、特徴空間で線形識別関数を生成.

家庭内個別電気機器動作状態推定システムでは、上述した SVM を採用している.

#### 4. 実験結果

本章では、従来から非線形分類手法として知られる RBF ネットワークおよび SVM によって家庭内電気機器状態推定モデルを作成した結果について紹介する. RBF ネットワークは SVM の識別結果を比較するために用意した. 以下、4 章 1 節では RBF ネットワークおよび SVM のモデル選択について報告し、2 節で実験条件、結果について紹介する.

##### 4.1 モデル選択

SVM のような学習機械によってモデルを生成する場合、汎化能力の高い<sup>1</sup>モデルを注意深く見つけることが重要となる. ここで、汎化能力の高いモデルとは表現力が十分にあると同時に、複雑過ぎないモデルを意味する. モデルに十分な表現力がないと学習データを十分に学習することができないし、逆に非常に複雑なモデルを作成してしまうと与えられた学習データのみ適用できるモデルになってしまう. 以下では、十分な表現力を持ち、複雑過ぎないモデルを作成するため、実験で適用したモデルのパラメータの選択方法について紹介する.

家庭内電気機器状態推定システムに適用した SVM では RBF カーネルを使用している. その際、SVM で

生成されるモデルのパラメータとしては、以下の 2 つがある.

1. 学習データに対するマージンの大きさと学習データに対して誤分類してもよいデータ数とのトレードオフを決定する正則化パラメータ  $C$ .
2. 分類の精度 (粒度) を制御するパラメータ  $\sigma$ . このパラメータ  $\sigma$  は式 (1) 中の  $\sigma$  を意味し、RBF カーネルの分布の幅を決定付けるものである.

また、本実験では SVM との比較のために RBF ネットワークを採用した. SVM との比較のために用意した RBF ネットワークはモデルのパラメータとして、以下を有する [11].

1. ネットワークの中間層ユニット数  $m$ .
2. 正則化パラメータ  $\lambda$ .
3. 最適な中心位置を求める繰り返し回数  $I$ .

SVM や RBF ネットワークを適用する際には、2 つまたは 3 つのモデルのパラメータを推定する必要がある. 家庭内電気機器動作状態推定システムでは、適切なパラメータを推定するため、Leave-One-Out 交差妥当化法 [11] を用いてパラメータの推定を行なった. この Leave-One-Out 交差妥当化法は他のモデル選択方法に比べ、頑健で、信頼性の高い方法として知られているが、計算時間が膨大になるという欠点を持つ. 本実験ではパラメータの値の稼働範囲を表 2 に示したように設定し、この範囲で適切なパラメータの値を調べた.

<sup>1</sup>未学習データに対しても識別能力が高いことを意味する.

表 2: 各パラメータの稼働範囲

手法	パラメータ
SVM	$C = 10^{-1}, 10^0, \dots, 10^4, 10^5$ $\sigma = 10^{-3}, 10^{-2}, \dots, 10^2, 10^3$
RBF	$m = 3, 4, \dots, 9, 10$ $\lambda = 10^{-8}, 10^{-7}, \dots, 10^{-1}, 10^0$ $I = 0, 1, \dots, 14, 15$

## 4.2 実験条件および結果

本節では、家庭内電気機器動作状態推定システムのシミュレーション結果について紹介する。シミュレーション用のデータは、図2に示した家庭内の電気機器の接続状況を模擬できる測定回路を作成し、収集した。収集した測定データの条件を次に示す。

- 家庭内電気機器として、表1に示したインバータエアコン2機、扇風機1機、白熱灯5個、蛍光灯5本、インバータ蛍光灯5本、テレビ2台、電気ポット1台、冷蔵庫1台を設置。
- 各電気機器のオン・オフ動作状態の組合せを変えて、データ数 23,014 のデータを測定。

家庭内個別電気機器動作状態推定問題に対するSVMとRBFネットワークの能力を統計的に評価するため、23,014の測定データ全てをランダムに分割し、10個の学習データ・テストデータの組を生成した。その10組の学習データ・テストデータを用いてシミュレーションを行なった。具体的には、以下の手順によりシミュレーションを行なった。

1. 23,013の観測データをランダムに分割し、5,000個の学習データと18,013個のテストデータの組を生成。
2. ランダムに生成する学習(5,000個)・テストデータ(18,013個)の組を10組生成。
3. 各学習・テストデータの組ごとに、学習データを用いて前節で述べたモデルのパラメータ推定を実行。
4. 選択したモデルのテストデータに対する誤識別率を計算。

表 3: テストデータに対する平均誤識別率 (%)

手法	RBF	SVM
インバータエアコン1	4.3±0.1	2.5±0.0
インバータエアコン2	3.5±0.1	2.3±0.1
扇風機	5.2±0.1	3.2±0.1
白熱灯	7.3±0.1	5.0±0.1
蛍光灯	1.7±0.1	0.9±0.0
インバータ蛍光灯	2.6±0.1	1.3±0.1
テレビ1	2.0±0.1	1.4±0.0
テレビ2	2.9±0.1	1.9±0.1
電気ポット	24.8±0.2	19.7±0.1
冷蔵庫	3.2±0.1	1.5±0.0
全機器平均誤識別率	5.7±0.0	4.0±0.0

5. 10組のデータセットごとのテストデータ(18,013個)に対する誤識別率を獲得。

テストデータに対する識別能力をより正確に評価するため、10組得られたテストデータに対する誤識別率を平均するとともに、信頼性区間を計算した。その結果を表3に示す。表3より、個別電気機器の動作状態の推定はRBFネットワークよりSVMの方が低い誤識別率を示しており、全ての電気機器に対する平均的な誤識別率もSVMがRBFネットワークより低いことがわかる。つまり、本報告で用いた測定データによる家庭内電気機器動作状態推定に対して、SVMが識別能力の高い安定した識別器となっていることがわかる。

## 5. まとめと今後の展開

本稿では、一般家庭における電気機器のオン・オフ状態を電気機器から発生する高調波パターンに基づき推定する非侵入型のモニタリングシステムに、SVMを用いた場合について述べた。

従来、非侵入型モニタリングシステムとして、文献[4]で提案されている方法が採用されてきた。しかし、文献[4]で紹介されているモニタリングシステムではインバータ回路を有さない電気機器のみのオン・オフ状態推定が可能であり、昨今普及の著しいインバータ回路を有する電気機器の状態推定が困難である。本論では、非侵入型モニタリングシステムにSVMを用いた実験結果を紹介し、SVMを適用することでインバータ式、ノンインバータ式が混在する中で、各電気

機器のオン・オフ動作状態を十分な精度で識別できることを紹介した。

今後は、非侵入型モニタリングシステムの実用化へ向けたフィールドテストを行なっていくとともに、学習データ数が増えると、飛躍的に学習時間が増加してしまう SVM の学習時間の短縮に取り組んでいく。特に、SVM 学習時間の短縮には、最適化手法の知見が重要となると思われる。

## 参考文献

- [1] O. Lance and O. Sidler. The do's and don'ts of running successful end-use metering campaigns. In *Workshop on Non-Intrusive and Other End-Use Metering Systems*. NOVEM and PW Consulting, 1998.
- [2] D. Cooper. Domestic end-use monitoring in the uk. In *Workshop on Non-Intrusive and Other End-Use Metering Systems*. NOVEM and PW Consulting, 1998.
- [3] 特許「小型消費電力測定装置」(特願平成 6-339916 号, 平成 6 年 12 月 29 日出願, 平成 8 年 7 月 16 日公開).
- [4] W. Hart. Non-intrusive appliance load monitoring. *Proceedings of the IEEE*, Vol. 80, No. 12, 1992.
- [5] J. Carmichael. Non-intrusive appliance load monitoring system. *Epri journal, Electric Power Research Institute*, 1990.
- [6] K. Yoshimoto and Y. Nakano. Application of neural network to a non-intrusive metering system for household electric appliances with inverters. In *Workshop on Non-Intrusive and Other End-Use Metering Systems*. NOVEM and PW Consulting, 1998.
- [7] 由本勝久, 中野幸夫. 非侵入型モニタリングシステムの開発(その1):ニューラルネットワークによるインバータ機器の同定. 研究報告書, (財)電力中央研究所, 1999.
- [8] V.N. Vapnik. *The Nature of Statistical Learning Theory*. Springer, 1995.
- [9] B.E. Boser, I.M. Guyon, and V.N. Vapnik. A training algorithm for optimal margin classifiers. In D. Haussler, editor, *5th Annual ACM Workshop on COLT*, pp. 144-152, Pittsburgh, PA, 1992. ACM Press.
- [10] M. Aizerman, E. Braverman, and L. Rozonoer. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and Remote Control*, Vol. 25, pp. 821-837, 1964.
- [11] C.M. Bishop. *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford, 1995.