建物の外から電気機器の使用実態を把握するモニタリング装置へのニューラルネットワークの応用

正員 由本 勝久 (電力中央研究所) 正員 中野 幸夫 (電力中央研究所)
学生員 天野 好輝 (東京農工大学) 非会員 ケルマンシャヒ バフマン (東京農工大学)

Neural Networks Applied to Non-Intrusive Load Monitoring System
Katsuhisa Yoshimoto, Member (Central Research Institute of Electric Power Industry),
Yukio Nakano, Member (Central Research Institute of Electric Power Industry),
Yoshiteru Amano, Student (Tokyo University of Agriculture and Technology) and
Bahman Kermanshahi, Non-member (Tokyo University of Agriculture and Technology)

A non-intrusive load monitoring system has been developed to ascertain each electrical appliance in a household by disaggregating the total load demand. This system does not need to intrude into a house when metering power consumption of each appliance. Therefore, the system has significant cost advantages and is less troublesome to the customers. This paper describes a non-intrusive load monitoring system which is especially useful when the household has inverter-driven appliances that frequently change their operational state. Conventional non-intrusive load monitoring system cannot treat these inverter-driven appliances easily because of their complicated operation. In the developed system, the load consumption of household appliances is identified by a Neural Network, which perceives the pattern of harmonics flowing out of the house. An air conditioner, a refrigerator, an incandescent lamp, a fluorescent lamp and a television set were used as household appliances for experiments of inference tests. From the experimental result, it was verified that the NN could identify the load consumption of an inverter-driven air conditioner from the pattern of harmonics of the total load. For this reason, the non-intrusive load monitoring system for the household which has several appliances including inverter-driven appliances is viewed as reliable.

キーワード：建物外，モニタリング装置，電気機器，使用実態把握，ニューラルネットワーク

Keywords: non-intrusive, monitoring system, electrical appliance, load survey, neural network

1. はじめに

需要家の保有する電気機器の構成や個別の使用実態に関する情報の調査は、モニタリングと呼ばれており、需要家のニーズを把握したり将来の電力需要の動向を予測したりする上で、極めて重要となる。また、省エネルギーのポテンシャルを量る上でも重要である。このモニタリングを行う方法として一般に用いられているのは、電気機器や給電回路にセンサーやデータ収録装置を取り付けたり、家庭に対しアンケートを行うなどの方法である。しかし、この方法は、需要家の建物内に立ち入って装置を設置する作業や配線工事などが必要なため、多大な労力やコストを要する。さらに、工事やデータ回収に関連して需要家に負担を強いる。そこで、需要家の建物内に立ち入らないで電気機器ごとの使用実態を把握する方法が望まれる。

そこで本研究では、消費電力が一定ではないインバータ機器を含む複数の電気機器を有する一般家庭の給電線入口付近で得られる情報から、電気機器ごとの消費電力を推定

する手法ならびに装置を開発することを目的としている¹⁾。今回は、電気機器個別の消費電力を推定するアルゴリズムを二種類（回帰法とクラスタリング法）開発し、実験によりその有効性を確認したので報告する。なお、建物外で得られる情報として、電力量計付近で計測する電流の高調波パターンに着目した。電気機器が稼動すると、電気機器固有のパターンを持つ高調波が発生する。そこで高調波のパターンと電気機器の消費電力との相関を学習するパターン認識手法（ニューラルネットワーク）を応用することで、電気機器の消費電力を推定するアルゴリズムを開発した。

以下、本論文では第2章で本モニタリング装置について概説し、第3章で電気機器の使用状況と高調波の関係について述べる。次に第4章でニューラルネットワークを応用したモニタリング装置について述べ、第5章で実験室にて実測したデータを用いた検証実験について述べる。最後に、本論文のまとめを行う。

2. 建物内に立ち入らないモニタリング装置

これまでに行われている電気機器ごとのモニタリングは、需要家内に立ち入る必要があるため intrusive 型のモニタリングと呼ばれる。この方法では、技術者が装置を取り付ける労力、家庭に対する負担、さらには設置のためのコストなど、多くの家庭を対象とした場合には問題が生じる。このため、コストや需要家への負担を極力少なくした方法が望まれる。すなわち、需要家の建物内に立ち入ることなく、電気機器の使用実態をモニタリングする方法が望まれる。このような方法は non-intrusive 型⁽¹⁾と呼ばれる。

図1は建物内に立ち入らないモニタリング装置の概念図であり、一般家庭の給電線の入り口位置に取り付けたモニタリング装置が建物の外から家庭内の電気機器の稼動状態を推定する様子を表している。すでに、EPRI (Electric Power Research Institute; 米国)では、MIT (Massachusetts Institute of Technology; 米国)で開発したアルゴリズムに基づいて⁽¹⁾、需要家の給電線入口位置で得られる情報のみから電気機器の稼動状態を推定する装置を開発している⁽²⁾。また、その他にも活発に研究されている⁽³⁾。これらのシステムでは、基本的に、総消費電力の時間推移を常時監視し、総消費電力・力率のステップ状の変化の具合から、オン・オフ動作をした機器を推定している。したがって、これらのシステムで用いられているアルゴリズムは、主に ON/OFF 機器^注が対象となる。しかしながら、インバータエアコンのように昨今普及の著しいインバータ搭載機器では、消費電力が使用状況によって無段階に変動し、単純なオン・オフ動作を行っていないので、ステップ状の変化を利用するアルゴリズムでは対応が難しい。日本では、省エネルギー推進のために電気機器のインバータ化が行われているために、これらのアルゴリズムでは問題が生じる。ま

図1 建物内に立ち入らないモニタリング装置
Fig. 1. Non-Intrusive Load Monitoring System

注 動作状態がオンまたはオフの二値しか取らない機器。

た、同時に複数台の機器のオン・オフ動作が行われた場合も、機器の稼動状態を推定するのが難しい。そこで、本研究では電気機器が発生する高調波に着目し、給電線入口付近を流れる高調波電流のパターンから、下流に接続されている電気機器の稼動状態を推定することとした⁽⁴⁾。

建物の外から電気機器の使用実態を把握するという用途を考えて、このようなモニタリング装置は、多くの家庭に適用して需要家の電気機器の利用傾向を分析したり、使用パターンを把握するためのツールとして有用と考え、そのため本研究では消費電力の推定が概ね正解であれば良いものとした。なお、正確に消費電力を把握したい場合は、intrusive 型のモニタリングが必要となる。

3. 高調波電流について

<3・1>電圧と発生する高調波電流 図2は 50Hz の商用電源における電圧とある機器が稼動している時の電流の例である。同図では、1 サイクル分の波形を示している。電圧に歪みのない正弦波を用いても、使用する電気機器に抵抗素子以外のものがあると電流波形は歪む。この歪み波形は、フーリエ変換などの方法を用いることで電圧の整数倍の周波数を持つ波に分解することができる。この倍数のことを次数という。図3は図2の電流波形を各高調波次数ごとに分けたものである。各次数の振幅と位相は表1に示すとおりである。なお、偶数次の高調波は無視できるほど小さいため、本研究では対象としない。

<3・2>電気機器の使用状態と高調波パターン 図4(a)~(c)は、高調波測定装置を用いて測定したある機器群が稼動した場合の高調波電流の例である。図中の表は、電気機器個別の消費電力を示している。グラフは基本波(第1次)から第13次までの奇数次の高調波電流と基本波電圧に対する各電流の位相差を示している。なお、位相差は正弦値で示してある。(a)と(b)を比較すると、機器のオン・オフの組み合わせは同じであるがエアコンの消費電力が異なるために発生する高調波パターンも異なるのが分かる。(a)と(c)を比較すると、総消費電力が同じであるにもかかわらず、機器の組み合わせが異なるために、高調波パターンも異なるのが分かる。これらの違いの原因は、機器の稼動状態ごとに固有の高調波が発生することによる。したがって、これら電気機器の状態と高調波パターンとに強い相関関係がある。そこで、電気機器個別の消費電力と高調波パターンとをパターン認識手法で関連付けることにより、建物の外から電気機器個別の消費電力を推定できると考えた。

なお、実際の商用電源の電圧には僅かだが歪みがあり、その形状は外部の電気の使用状況によって時々刻々変化している。そのため、特定の電気機器から発生される高調波電流もその影響を受ける。つまり、高調波パターンを用いた電気機器の稼動状態の推定は、外部からのじょう乱のあるパターン認識問題となる。したがって、推定アルゴリズムとなるパターン認識手法には高い汎化能力が求められ、過学習を避けるなどの対応が必要となる。

図2 ある機器が稼動している時の電圧と電流の関係
Fig. 2. Relation of Voltage and Current in the Case of an Appliance working

図3 各次数の高調波電流
Fig. 1. Harmonic Current of Each order

表1 各次数の高調波電流の振幅と位相

	基本波	3次	5次	7次
振幅[A]	1	0.5	0.1	0.05
位相[度]	10	35	200	80

4. ニューラルネットワークを用いた推定アルゴリズム

<4・1> 基本アルゴリズム 図5は推定アルゴリズムで用いるニューラルネットワーク^{5), 6)}の概略図である。左側にある入力層のユニットへ1～13次の奇数次高調波電流と基本波電圧との位相差(正弦値)が入力され、右側の出力層の各ユニットからはそのときの電気機器の消費電力を表す値が出力される。電気機器の消費電力の表し方としては2種類考案した。すなわち、一つは消費電力を定格に対する百分率として直接出力する方法(回帰法)、もう一つは機器の消費電力をいくつかの領域に分けて、どの領域に消費電力があるかを0, 1の二値で示す方法(クラスタリング法)である。なお、ニューラルネットワークの学習アルゴリズムは、バックプロパゲーションアルゴリズム(誤

(a) 高調波パターンの例(1)

(b) 高調波パターンの例(2)

(c) 高調波パターンの例(3)

- A: インバータエアコン
- B: インバータ冷蔵庫
- C: 白熱灯
- D: 蛍光灯
- E: テレビ

図4 高調波パターンの例
Fig. 4. Examples of Harmonics Patterns

図5 建物内に立ち入らないモニタリング装置のためのニューラルネットワーク

Fig. 5. Neural Network for Non-Intrusive Load Monitoring System

図6 回帰法のイメージ
Fig. 6. Regression Method

差逆伝播アルゴリズム)を用いている。

<4・2> 回帰法 回帰法は、高調波パターンと各電気機器の電力消費の相関関係を回帰的にニューラルネットワーク上に構築し、高調波パターンから機器の消費電力を直接的に出力する方法である。図6に回帰法による消費電力推定のイメージを示す。同図では、時刻 t とも変化する総消費電力(測定データ)を電気機器ごとの消費電力に弁別する様子を表している。実際には、総消費電力を直接に弁別するのではなく、総消費電力の電流から求めた高調波パターンを入力、各電気機器の消費電力を出力とする回帰式をニューラルネットワークの構造式という形で学習により構築して、弁別を行っている。

ところで、シグモイド関数を用いるニューラルネットワークは0～1の間の値を扱うが、一般的に、測定したデータ値は0～1の範囲内にはない。そこで、入出力データに前処理と後処理を施す。本論文では、ニューラルネットワークへの入力データは(1)～(3)式で正規化を行い、出力は(4)式により正規化を行うこととした。

$$x_{i1}(\text{基本波電流値}) \rightarrow \frac{x_{i1}}{\text{MAX}(x_{i1})} \dots\dots\dots (1)$$

$$x_{ij}(\text{第3～13次高調波電流値}) \rightarrow \frac{x_{ij}}{x_{i1}} \dots\dots\dots (2)$$

$$y_{ij}(\text{基本波及び高調波位相差}) \rightarrow \text{SIN}(y_{ij}) \dots\dots\dots (3)$$

$$P_k(\text{各機器の消費電力}) \rightarrow \frac{P_k}{\text{MAX}(P_k)} \dots\dots\dots (4)$$

ここに、 N :データ数、 $i=1,\dots,N$ 、 j :高調波次数(3,5,...,13)、 k :機器番号 ($1=A, 2=B, 3=C, 4=D, 5=E$)

(1)式では基本波電流の、(4)式では各機器の消費電力の最大値を用いて正規化している。(2)式では第3～13次の奇数次高調波電流を基本波電流の比率とし、(3)式では位相差を正弦値(SIN)としている。なお、推定値は、機器個別の消費電力を定格消費電力の百分率で表す。

<4・3> クラスタリング法 クラスタリング法では、機器の消費電力をいくつかの領域に分割し、稼動中の機器の消費電力を対応する領域に振り分けること(クラスタリング)によって消費電力を直接的にはではなく、ある幅を持たせて表す。領域の表し方については、今回は機器の特性を考えて以下のように行った。すなわち、図5に示す出力層のユニットA、Bに対応するインバータエアコンとインバータ冷蔵庫については、消費電力を分割して領域を作り、ユニットC～Eの電灯やTVについてはON/OFF機器として扱う。具体的には、図7に示すとおりである。インバータエアコンについては、定格出力を最大として消費電力を100Wごとの領域に区切る。そして、領域それぞれにニューラルネットワークのユニットを対応づけて、ユニット出力が1のとき、その領域内にエアコンの出力があるものとし、ユニット出力が0のときはその領域内にはないものとする。なお、OFF状態に対応するユニットも設定し、ユニット出力が1のときエアコンはOFF状態にあるものとし、ユニット出力が0のときはOFF状態にはないものとする。

インバータ冷蔵庫については、インバータエアコンと同様の方法とするが、領域分けを一定幅で行うのではなく、「OFF」・「待機^注」・「コンプレッサー稼動」の3つのモードに分けて行う。電灯とテレビについては、ON/OFF機器として扱い、ON/OFFを表すユニットをそれぞれ一つだ

ユニットA	OFF	1W～100W	101W～200W	201W～300W	
インバータエアコン 0,1出力					
ユニットB	OFF	1W～50W	80W～160W		
インバータ冷蔵庫 0,1出力					
ユニットC, D, E (電灯とテレビ)	ON/OFF	1; ON 0; OFF			

図7 領域分けの方法
Fig. 7. Method of Partitioning

^注電源が入っているがコンプレッサーが稼動していない状態。

け設定する。すなわち、ユニット出力が1のときON（稼動中）、0のときOFF（停止）とする。

<4・4>手法の特徴 ここでは回帰法とクラスタリング法の特徴をまとめ、2種の手法の開発目的を明らかにする。

回帰法では、0～1の連続値を用いるので、より直接的に消費電力を指定できる。したがって、家庭の電力消費実態の内訳を詳細に把握したいときは有用である。しかし、推定値の誤差を小さくするには、学習誤差（教師信号とニューラルネットワークの出力との差）をクラスタリング法のそれより小さくする必要があり、多大な計算時間が必要となる。また、データのじょう乱がニューラルネットワークの出力に揺らぎを与える場合、クラスタリング法と比較して推定結果に対する影響が大きくなってしまう。

一方、クラスタリング法では、消費電力が対応する領域に属するかどうかを0または1の値で示すだけなので、学習誤差を小さくする必要が少ない。また、データにじょう乱があっても、領域の切り分け方が適切であれば、出力の揺らぎが推定結果に与える影響は小さく、じょう乱に対して比較的ロバストである。しかし、ある幅を持たせて消費電力を表現するため、大まかにしか消費電力を推定できない。

このようなことから、消費電力が広い範囲で連続的に分布している場合には回帰法を用い、領域に分かれている（クラスタを形成している）場合はクラスタリング法を用いるという使い分けが有用となる。実際にモニタリングシステムに应用する際には、これらの特徴を勘案して適切な方法を選択すべきである。また、少数の家庭を対象として特定の機器の消費電力を詳細に調べたいときには回帰法、大まかでもいいが多くの機種・家庭で調査したい場合にはクラスタリング法、などの使い分けも考えられる。

5. 推定システムの検証実験

<5・1> 検証実験の概要 一連の実験で使用するデータの収集は、一般家庭の屋内配線を模擬した図8の測定装置を使用して行った。この装置では、電圧センサ（Main PT）および電流センサ（Main CT）により、主幹回路における電流および電圧を測定するとともに、それらのデータを高速

図8 高調波データ測定装置
Fig. 8. Harmonics Data Collection System

表2 使用した電気機器

Table 2. Appliances used in Experiment

	機器名	定格消費電力[W]
A	インバータエアコン	500
B	インバータ冷蔵庫	150
C	白熱灯	100×6
D	蛍光灯	20×6
E	テレビ	65

表3 学習データ及び検証用データの分布

Table 3. Distribution of Learning and Unseen Data

(a)学習データ

	家電機器記号				
消費電力[%]	A	B	C	D	E
0	104	143	135	143	140
10	61	86	0	0	0
20	0	0	0	0	0
30	1	0	0	0	0
40	0	0	0	0	0
50	4	0	0	0	0
60	0	0	0	0	0
70	0	59	0	0	0
80	87	26	0	1	0
90	37	11	0	177	155
100	33	2	192	6	32
	合計 =327				

(b)検証用データ

	家電機器記号				
消費電力[%]	A	B	C	D	E
0	540	649	613	652	630
10	260	390	0	0	0
20	0	0	0	0	0
30	7	0	0	0	0
40	7	0	0	0	0
50	12	0	0	0	0
60	2	0	0	0	0
70	5	269	0	0	0
80	373	119	0	5	0
90	169	59	0	815	733
100	125	14	887	28	137
	合計=1500				

フーリエ変換することで、総消費電力における高調波電流や位相差を任意の測定間隔で測定できる。また、各分岐回路に接続された電力計(W-A,W-B,...,W-E)により電気機器

個別の消費電力も測定できる。ここで、測定に用いた電気機器5種を表2に示す。図8中に示すスイッチ SW-A～SW-Eを適宜切り替えることで機器の組み合わせを変更し、合計1827組のデータを収集した。そして、乱数を用いて測定データより学習データをランダムに選択し、残りを検証用データとした。表3にその内訳を示す。表3中のA～Eは表2の電気機器と対応している。なお、インバータエアコンについて、計測中は連続運転させて等時間間隔でデータ収集しているだけで、恣意的に消費電力をコントロールしなかったことに注意されたい。

＜5・2＞ 回帰法の結果

(a) 学習の結果 表3の学習データおよび表4に示すような学習パラメータを用いて学習を行った。なお、これらのパラメータはいくつかの予備実験を通して試行錯誤的に決定したものである。また、ニューラルネットワークの学習の成否は初期重みに依存するので、10通りの初期重みを用意し、それぞれについて学習を行った。ここに、初期重みは-1～1の範囲で乱数を発生させて作成した。

学習終了判定は次のように設定した。

- ① 平均絶対誤差が0.01以下
- ② 各学習パターンに対してネットワークの出力値と教師信号の誤差が0.1以下
- ③ 学習のサイクルが200万回を越えたとき(1サイクルは一通りの学習データをニューラルネットワークに提示したとき)

その結果、全ての試行で①は満たすものの、②を満足できず、③の200万回の学習サイクルが経過し、学習が打ち切られた。収束条件②は、全学習データに対して正解となるための条件であり、厳密に学習を行わせるために付加した

表4 回帰法で使した学習パラメータ
Table4. Learning Parameters used in Regression Method

中間層のユニット数	14
学習率	0.2
シグモイド関数の傾き	1.0
モーメント項の係数	0.2

図9 回帰法の検証用データに対する正解率
Fig. 9. Correct Answer Rate by Regression Method

条件である。建物の外から電気機器の使用状態を把握するという用途を考えると、100%の正解率を達成しなくとも十分であることから、学習が完了したものとした。また、過学習の影響が懸念されることからこのようにした。

(b) 推定能力の検証 回帰法を用いたニューラルネットワークの推定能力を検証するために、表3に示す1500個の検証用データに対して電気機器個別の消費電力を推定する実験を行った。10ケース分のネットワークに対する検証結果を図9に示す。図中の正解率とは、全検証用データ中、推定誤差±10%以内を正解として、その範囲内に入った場合の割合である。全ての機器において、正解率の平均は98%以上となっている。なお、図中の「ALL」は全機器を同時に正解した場合を意味する。

次に、各ケースで全機器の正解率を平均し、最良の結果を示したネットワークの推定結果の詳細を図10(a)～(e)に示す。図中の斜線は正解とした誤差範囲±10%を示している。インバータエアコンの結果を見ると、20%から70%の範囲で大きく外れている。これは、検証用データには20%から70%の範囲に少数ながらデータがあるものの、学習データにはわずかなデータしかなかったためだと考える。なお、他の機器でも不正解のプロットがあるが、図9の正解率から、不正解の数は正解に比して圧倒的に少なく、実用上問題にならないと考える。グラフのプロットが重なると1点にしか見えないため、正解の領域内にあるプロットが少なく見えてしまうことに注意されたい。

＜5・3＞ クラスタリング法の結果

(a) 学習の結果 表3の学習データおよび表5に示すような学習パラメータを用いて学習を行った。なお、これらのパラメータはいくつかの予備実験を通して試行錯誤的に決定したものである。また、ニューラルネットワークの学習の成否は初期重みに依存するので、10通りの初期重みを用意し、それぞれについて学習を行った。ここに、初期重みは-1～1の範囲で乱数を発生させて作成した。

学習終了判定は次のように設定した。

- ① 各学習パターンに対してネットワークの出力値と教師信号の誤差が0.3以下
 - ② 学習のサイクルが20万回を越えたとき
- 以上のようにして学習を行ったが、ほとんどのケースでただ一つの学習データに対して誤差が0.3以下とならずに規定の学習サイクル数を超えてしまった。しかし、一例外を除く全学習データについて学習ができたといえるので、学習が完了したものとした。

表5 クラスタリング法で使した学習パラメータ
Table 5. Learning Parameters used in Clustering Method

中間層のユニット数	15
学習率	0.1
シグモイド関数の傾き	0.3
モーメント項の係数	0.5

図 10 回帰法による機器ごとの推定結果

Fig. 10. Actual Data and Estimated Results of Each Appliance by Regression Method

(b) 推定能力の検証 クラスタリング法を用いたニューラルネットワークの推定能力を検証するために、回帰法で用いたのと同じ表 3 の 1500 個の検証用データに対して推定実験を行った。なお、ニューラルネットワークの出力値は 0~1 の連続値のため、0 または 1 のどちらかの値となるように、出力層のユニット出力が 0.5 以上のとき 1、0.5 未満のとき 0 とした。

10 ケース分の検証結果を図 11 に示す。クラスタリング法では、実消費電力を含む領域を正しく推定できたときを正解とした。図中の正解率は、全検証用データ中、ニューラルネット

ワークが正しい領域を推定できた場合の割合である。なお、図中の「ALL」とは、全機器を同時に正解したときの割合である。同図より、ほぼ 100% の正解率で機器の稼動状態を推定できている。全機器を同時に正解した割合についても全ケースで 96% 以上と非常に高い正解率となっている。

エアコンと冷蔵庫については、領域ごとの正解率を求めたので、それぞれ図 12、13 に示す。なお、図中「not」は、その領域に消費電力が属していないときを示し、この場合はユニット出力が 0 のとき正解となる。エアコンの正解率について 101-200W の領域で正解率が 40% よりも低いのは、回帰法の結果と同じく、この領域の学習データの数が他の領域と比べて少ないからだと考える。冷蔵庫については、各領域ともほぼ 100% の正解率が得られている。

ここで、エアコンや冷蔵庫について複数の消費電力を推定してしまう（その機器に対応しているユニットで複数値 1 を出力している）場合についても正解にカウントしている。しかしながら、「not」の場合の正解率は 100% に近いので、複数の領域を推定結果として提示してしまうことは少なかったといえる。

<5・4> 結果の考察 ここでは回帰法とクラスタリング法とで得られた結果を考察する。

回帰法、クラスタリング法の両方とも、それぞれの正解率の定義は異なるが、検証用データに対する正解率が 97% 以上と非

図 11 クラスタリング法の検証用データに対する正解率
Fig. 11. Correct Answer Rate by Clustering Method

図 12 エアコンの各消費電力領域における正解率

Fig. 12. Correct Answer Rate of Each Watt Range in Air conditioner by Clustering Method

図 13 冷蔵庫の各消費電力領域における正解率

Fig. 13. Correct Answer Rate of Each Watt Range in Refrigerator by Clustering Method

常に高い。エアコンでは一部の稼動状態（消費電力100W～300W）で正解率が低いが、学習データを十分に用意できれば、さらに正解率が高くなると予想される。これより、建物内に立ち入らずに電気機器個別の消費電力を推定するアルゴリズムとしてのニューラルネットワークの有効性を確認できた。

ここで、図9と図11から回帰法とクラスタリング法で得られた結果の違いについてみると、ON/OFF機器ではクラスタリング法が、そうでない機器では回帰法が若干だが優れた正解率を出している。しかしながら、それぞれ消費電力の表現方法が異なるために、正解率の定義が統一されていない状態での比較であるので、一概にはどちらが優れているとは言えない。回帰法では誤差何%までを許容するか、クラスタリング法での領域の幅をどの程度にするかが正解率に大きな影響を与える。また、実消費電力からの誤差と領域を正しく指定できたかどうかを同じ基準で比較するのは難しい。したがって、適用先の特徴によってどの手法を選択するのかと同時に、どのように正解率を定義するかを考慮する必要があることに注意されたい。

6. おわりに

本論文では、建物内に立ち入らずに電気機器の使用実態をモニタリングする装置を開発するために、ニューラルネットワークにより電気機器個別の消費電力を家庭の給電線入り口付近

を流れる高調波のパターンから推定する手法を二種類提案し、実験によりその有効性を確認した。提案した手法は回帰法とクラスタリング法である。電気機器を5種類使用した推定実験の結果、回帰法、クラスタリング法とも、検証用データに対する推定の正解率は97%以上と非常に高かった。建物の外から電気機器の使用実態を把握するという用途を考えると、この正解率は十分であると考ええる。しかし、消費電力別の推定結果を見ると、消費電力が広い範囲にわたるインバータエアコンでは、学習データの消費電力分布に偏りがあったため、学習が十分に行えなかった範囲があった。他の機器では、著しく正解率が劣る消費電力範囲は見られなかった。エアコンに関しては、学習データの充実により正解率は広い範囲で向上するものと考えられる。

以上より、建物に立ち入らないモニタリング装置の開発の目処が得られた。今後の課題を挙げると、

- (1) 推定精度向上のために、ニューラルネットワークの構築法の検討・学習データの充実・他のパターン認識手法の適用を検討する
- (2) 外部じょう乱の影響が強い場合、すなわち、外部からの高調波が大きい場合、さらには実家庭並に電気機器の機種と台数がある場合のニューラルネットワークの推定能力を検証する

などが考えられる。

(平成13年7月10日受付、平成14年3月15日再受付)

文 献

- (1) G. W. Hart, "Nonintrusive Appliance Load Monitoring", Proceedings of IEEE, Vol. 80, No. 12, pp.1870-1891, Dec. 1992.
- (2) L. Carmichael, "Nonintrusive Appliance Load Monitoring System", EPRI Journal, Sept. 1990, pp.45-47.
- (3) Norford, L. K. and S. B. Leeb. 1996. "Non-Intrusive Electrical Load Monitoring in Commercial Buildings based on Steady-State and Transient Load-detection Algorithm." Energy and Buildings 24, 1996, pp.51-64.
- (4) 由本, 中野「非侵入型モニタリングシステムの開発(その1)ーニューラルネットワークによるインバータ機器の同定」, 電中研研究報告 T98045, 平成11年5月
- (5) (社)日本工業技術振興協会, ニューロコンピュータ研究部会:「ニューロコンピューティングの基礎理論」, 海文堂, 1990
- (6) 坂和正敏, 田中雅博:「ニューロコンピューティング入門」, 森北出版, 1997

由本 勝久 (正員) 1967年7月15日生まれ。96年3月東京都立大学大学院工学研究科電気工学専攻博士課程修了。同年4月(財)電力中央研究所に入所、現在に至る。博士(工学)。主として、電力系統及び分散型エネルギーシステムの計画・運用、非侵入型モニタリングシステムに関する研究に従事。オペレーションズ・リサーチ学会会員

中野 幸夫 (正員) 1957年3月4日生まれ。81年3月名古屋大学大学院工学研究科博士前期課程電気工学専攻修了。同年4月(財)電力中央研究所入所。超高圧架空送電線の電気環境問題、赤外線加熱、放射冷暖房、民生部門の省エネ、非侵入型モニタリングシステム等に関する研究に従事。現在、同研究所需要家システム部上席研究員。博士(工学)。95年2月～96年1月米国ローレンスパークレー国立研究所エネルギー・環境部客員研究員。

天野 好輝 (学生員) 1978年2月19日生。2000年3月東京農工大学電子情報工学科卒業。2002年3月同大学大学院工学研究科電子情報工学専攻博士課程修了。同年4月NHK入局、現在に至る。

ケルマンシャヒ バフマン (正員) 1956年5月6日生まれ。1985年日本大学理工学部電気工学科卒業。1990年東京都立大学大学院工学研究科電気工学専攻博士課程修了。工学博士。同年CSD(株)に入社。1991年から1994年まで、カナダのマニトバ州立大学客員教授。1994年電力中央研究所客員研究員。1995年東京都立大学工学部電気工学科助教授。1998年から東京農工大学大学院工学研究科環境エネルギー工学講座助教授、現在に至る。主として、電力系統工学の計画・運用、需要予測、インテリジェント工学(特にニューラルネットワーク、遺伝的アルゴリズム)検討に従事。電気学会、電気設備学会、米国のIEEEおよびNeural Network Society 正員。1991年電気設備学会論文賞受賞。