屋外からの家庭内電気機器消費電力推定における 機械学習手法の性能評価

非会員 村田 博士* 非会員 小野田 崇*
正員 由本 勝久** 正員 中野 幸夫**

Comparison of Machine Learning Techniques for Estimating the Power Consumption of Household Electric Appliances

Hiroshi Murata*, Non-member, Takashi Onoda*, Non-member, Katsuhisa Yoshimoto**, Member,
Yukio Nakano**, Member

A non-intrusive monitoring system estimates the behavior of individual electric appliances from the measurement of the total household load demand curve. The total load demand curve is measured at the entrance of the power line into the house. The power consumption of individual appliances can be estimated using several machine learning techniques by analyzing the characteristic frequency contents from the load curve of the household. In this paper, we present results of applying several regression methods such as multi-layered perceptrons (MLP), radial basis function networks (RBFN) and Support Vector regressors (SVR) to estimate the power consumption of an air conditioner. Our experiments show RBFN can achieve the best accuracy for the non-intrusive monitoring system.

キーワード：モニタリングシステム、非侵入型、回帰、ニューラルネットワーク、サポートベクターマシン、RBF ネットワーク

Keywords: Load monitoring system, Non-intrusive, Regression, Multi-layered perceptron, Support vector machine, RBF networks

1. はじめに

需要家の保有する電気機器の構成や使用実態に関する情報は、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、需要家への各種の確か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。従来、電気機器ごとの使用実態を測定するためには、家庭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。しかし、この測定方式では、家庭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、家庭内へ入ることなく、各電気機器の動作状態を推定する方法の開発が必要である。

この実現方法として、オン・オフの動作が総負荷電力におけるステップ状の時間変化となる電気機器に対して、家庭への引込線付近で計測した総負荷電力を、各電気機器の負荷電力に弁別分離する方法がすでに提案されている⁽³⁾。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)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)が混在する場合、電気機器の動作状態を推定することが難しい。そこで筆者らは、総負荷電流の高調波成分のパターンを用いることで、インバータ機器、非インバータ機器の混在する家庭内の電気機器の消費電力をニューラルネットワークにより推定する方法を開発した⁽⁷⁾。

本論文では、さらなる推定精度の向上を目的として、電気機器の消費電力を推定するアルゴリズムに、代表的な機械学習手法であるサポートベクター回帰法(Support Vector

* (財) 電力中央研究所 情報研究所
〒 201-8511 東京都狛江市岩戸北 2-11-1
Communication & Information Research Laboratory, Central Research Institute of Electric Power Industry
2-11-1, Iwadokita, Komae-shi, Tokyo, 201-8511
** (財) 電力中央研究所 狛江研究所
〒 201-8511 東京都狛江市岩戸北 2-11-1
Komae Laboratory, Central Research Institute of Electric Power Industry
2-11-1, Iwadokita, Komae-shi, Tokyo, 201-8511

図 1 測定装置

Fig. 1. Structure of the measurement system.

Regression 以下, SVR), RBF ネットワーク (Radial Basis Function Network 以下, RBFN) を適用し, ニューラルネットワーク (Multi-Layered Perceptron 以下, MLP) と比較することでインバータ, ノンインバータ機器の混在する家庭内稼動中電気機器の消費電力推定に最も適した機械学習手法を明らかにする。

2. 測定装置および観測データ

〈2・1〉 測定装置 観測データの収集は, 一般家庭の屋内配線を模擬した図 1 の測定装置を使用して行った。図中の CT および PT はそれぞれ引込線入口に設置を想定している電流センサおよび電圧センサである。これらのデータを高速フーリエ変換 (FFT) することにより, 高調波電流値と基本波電圧に対する位相差のデータを得る。A, B, C, D, ... は接続されている電気機器を表しており, スイッチ SW-A, SW-B, SW-C, SW-D, ... を切り替えて, 測定する電気機器の組合せを変えることができる。その際, 各分岐回路に接続された電力計 (WA, WB, WC, WD, ...) により各電気機器の消費電力を測定できる。

消費電力推定アルゴリズムの学習には, 基本波成分および第 13 次までの奇数次高調波電流とその位相を利用している。13 次までの高調波成分としたのは, 測定装置の測定精度による。

〈2・2〉 観測データ 前述の測定装置を使用して, 実験のための 2 種類の観測データを収集した。

小規模データ 表 1 上に示す 5 種の電気機器を測定対象としたデータである。この測定では, スイッチの組合せを変更することで, 1,827 点のデータを収集した⁽⁷⁾。

大規模データ 測定対象電気機器数を表 1 下の 10 種類に増やし, データ点数を増やした観測データである。この測定では, 11,636 パターンのデータを収集した。この際, 白熱灯および 2 種類の蛍光灯は, 点灯時の個数を適宜変化させている。

3. 比較した機械学習手法

図 2 に MLP, SVR, RBFN を用いた電気機器消費電力

表 1 測定に使用した電気機器

Table 1. List of electric appliances for measurement.

Small dataset

	Appliances	Maximum
A	Air conditioner	500W
B	Refrigerator with inverter	150W
C	Incandescent light	100W×6
D	Fluorescent light	20W×6
E	Television	65W

Large dataset

	Appliances	Maximum
A	Air conditioner 1	1000W
B	Air conditioner 2	1000W
C	Electric fan	100W
D	Incandescent light	50W×5
E	Fluorescent light	40W×5
F	Fluorescent light with inverter	50W×5
G	Television 1	65W
H	Television 2	80W
I	Electric pot	100W
J	Refrigerator	150W

図 2 電気機器消費電力推定システムの概略

Fig. 2. Sketch of monitoring system for power consumption.

推定システムの概略図を示す。以下では, 本報告で消費電力推定能力を比較した MLP, SVR, RBFN について簡単に紹介する。

〈3・1〉 ニューラルネットワーク (MLP) MLP は, 複数のしきい値ユニットからなるネットワークである。入力層には, 特徴ベクトル $\mathbf{x}$ の成分 $x_1, \dots, x_l$ が入力され, 中間層を経て出力層から出力される。この MLP の学習には次に述べる誤差逆伝播法 (back propagation method) が用いられる⁽¹⁾⁽⁸⁾。

ある層のユニット j を考える。ユニット j への入力 a_j は, ユニット j に接続するユニット出力 z_i の加重和となる。接続の加重を w_{ji} とすると, $a_j = \sum_i w_{ji} z_i$ と書ける。またユニット j の出力 z_j は, 非線形しきい値関数 h を用いて $z_j = h(a_j)$ と表される。入力層では, z_i が特徴ベクトルの成分 x_i となり, 出力層では, z_j が出力となる。

特徴ベクトル $\mathbf{x}^n$ を入力したときの出力ユニットの出力を z_k^n , $\mathbf{x}_n$ に対応する出力値を y_k^n とし, その誤差 E^n を $E^n = \frac{1}{2} \sum_k (y_k^n - z_k^n)^2$ とする。 E^n を最小化するように w_{ji} を決めるとすると, $\frac{\partial E^n}{\partial w_{ji}} = \frac{\partial E^n}{\partial a_j} \frac{\partial a_j}{\partial w_{ji}} = e_j z_i$ となり,

加重の修正は次式で行われる。

$$\Delta w_{ji} = -\rho \frac{\partial E^n}{\partial w_{ji}} = -\rho \epsilon_j z_i \dots \dots \dots (1)$$

ϵ は出力層のとき $\epsilon_k = y_k - z_k$ 、中間層のとき $\epsilon_j = h'(a_j) \sum_k w_{kj} \epsilon_k$ となる。

微分可能な非線形しきい値関数 h として、シグモイド関数

$$h(a) = \frac{1}{1 + \exp(-a)} \dots \dots \dots (2)$$

が用いられる。この微分は $h'(a) = h(a)(1 - h(a))$ となるので、 $\epsilon_j = z_j(1 - z_j) \sum_k w_{kj} \epsilon_k$ となる。

全体の誤差 E に対する偏微分は、すべての学習データについて上の計算を行うこととなり、すべてのパターンの和で表せる。

$$\frac{\partial E}{\partial w_{ji}} = \sum_n \frac{\partial E^n}{\partial w_{ji}} \dots \dots \dots (3)$$

〈3.2〉 SVR サポートベクトルマシン (以下、SVM) は、分類問題を解く学習アルゴリズムとして提案され、新たな機械学習の領域を構成するまでになった。分類問題を解く際、SVM は学習データから分類にとって重要となるデータ (サポートベクターと呼ばれる) を抽出し、それに基づき判別面を構成する。この特性を回帰問題にも適用したのが SVR である。Vapnik の提案する ϵ -SVR と呼ばれるアルゴリズムは次の関数を推定する⁽⁶⁾。

$$f(\mathbf{x}) = (\mathbf{w} \cdot \mathbf{x}) + b, \quad \mathbf{w}, \mathbf{x} \in \mathbf{R}^N, b \in \mathbf{R} \dots \dots \dots (4)$$

このとき、学習は次の損失関数を最小化することで行う。

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \cdot R_{\text{emp}}^{\epsilon}[f] \dots \dots \dots (5)$$

$\|\mathbf{w}\|$ は観測データを近似するモデルの複雑さを表す項であり、 $R_{\text{emp}}^{\epsilon}[f]$ は次式で表現される。

$$R_{\text{emp}}^{\epsilon}[f] = \frac{1}{\ell} \sum_{i=1}^{\ell} |y_i - f(\mathbf{x}_i)|_{\epsilon} = \frac{1}{\ell} \sum_{i=1}^{\ell} (\zeta_i + \zeta_i^*) \dots \dots \dots (6)$$

ここで、 $|y - f(\mathbf{x})|_{\epsilon} = \max\{0, |y - f(\mathbf{x})| - \epsilon\}$ であり、事前に与えられる $\epsilon > 0$ より小さい誤差にペナルティを与えないことを表す。 ζ^* は $-\epsilon$ 方向の緩和変数となる。また、 C は学習誤差とモデルの複雑性との均衡を決める定数である。

式 (5) の最小化は、次の 2 次計画問題を解くことで行う。ここで、(*) は * の有無に関わらないことを表す。

$$\begin{aligned} & -\epsilon \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) + \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) y_i \\ & -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j)(\mathbf{x}_i \cdot \mathbf{x}_j) \rightarrow \text{最大化} \end{aligned} \dots \dots \dots (7)$$

$$\begin{aligned} \text{制約条件} \quad & \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) = 0 \dots \dots \dots (8) \\ & \alpha_i^{(*)} \in [0, \frac{C}{\ell}] \end{aligned}$$

この最適化問題を解くことで得られる回帰モデルは $f(\mathbf{x}) = \sum_{i=1}^{\ell} (\alpha_i^* - \alpha_i)(\mathbf{x}_i \cdot \mathbf{x}) + b$ と表現される。

この関数は線形関数であるが、核関数を適用して非線形化への拡張が容易にできる。核関数は、特徴ベクトルの非線形変換 $\phi(\mathbf{x})$ の内積を特徴ベクトル $\mathbf{x}$ で表現するものであり、特徴ベクトルの持つ次元の演算で、高次元ベクトル演算をしたのと同様の結果が得られる。一般的には $k(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x}) \cdot \phi(\mathbf{y})$ のように表される。これにより、式 (7) は次のように変わるだけとなる。

$$\begin{aligned} & -\epsilon \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) + \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) y_i \\ & -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) k(\mathbf{x}_i, \mathbf{x}_j) \rightarrow \text{最大化} \end{aligned} \dots \dots \dots (9)$$

〈3.3〉 RBF ネットワーク RBFN⁽²⁾ は次式の線形モデルとして表現できる。

$$f(\mathbf{x}) = \sum_{j=1}^m w_j g_j(\mathbf{x}) \dots \dots \dots (10)$$

ここで、関数 f は m 個の基底関数 $\{g_j\}_{j=1}^m$ の線形結合で表現されている。この関数 f の柔軟性、つまり様々な関数に適合する能力は、加重 $\{w_j\}_{j=1}^m$ の値の自由度によって決まる。線形 RBFN の場合、モデルに含まれている基底関数や加重以外のパラメータは固定されている。

式 (10) の基底関数 $\{g_j\}_{j=1}^m$ には、微分可能であれば様々な関数が基底関数として利用できるが、RBFN では radial basis function を基底関数として用いる。この関数の特徴的な性質は、中心からの距離に対して関数の応答が単調減少あるいは単調増加することにある。radial basis function の一般的な表現は $g(\mathbf{x}) = \phi((\mathbf{x} - \mu)^T \mathbf{R}^{-1}(\mathbf{x} - \mu))$ となる。ここで、 μ は中心を表し、 $\mathbf{R}$ は計量を表す。関数 ϕ には、一般的に Gaussian 関数 $g(\mathbf{x})_j = \exp\left(-\frac{(\mathbf{x} - \mu_j)^2}{\sigma_j^2}\right)$ が用いられる。このパラメータは、中心 μ と半径 σ である。この Gaussian 関数は局所的であり、中央付近のみで十分な応答が得られる。これは生物の反応にも近い関数である。

RBFN の損失関数は、以下の式のようになる。

$$\sum_{n=1}^N \gamma_n (\hat{y}_n - f(\mathbf{x}_n))^2 + \frac{\lambda}{N} \sum_{j=1}^m w_j^2 \dots \dots \dots (11)$$

ここで、 N は学習データ数を、 $\hat{y}_n$ は出力 y_n に未知の雑音を加わったものを表す。また、 $\frac{\lambda}{N} \sum_{j=1}^m w_j^2$ は、過学習を避けるペナルティ項である。

4. 実験結果

本章では、2. で述べた観測データを使用して、MLP、SVR および RBFN のインバータエアコンの消費電力推定能力を比較した結果を報告する。

表2 各パラメータの稼働範囲

Table 2. Range of model parameters.

small dataset

Methods	Parameters
SVR	$C = 10, 20, 50, 100, 200, 500$ $\gamma = 0.01, 0.02, \dots, 0.07$
RBFN	$m = 10, 20, 30, 40$ $\lambda = 10^{-7}, 10^{-6}, 10^{-5}, 10^{-4}$ $I = 200, 300, 400$

large dataset

Methods	Parameters
SVR	$C = 10, 20, 50, 100, 200, 500$ $\gamma = 0.01, 0.02, \dots, 0.07$
RBFN	$m = 100, 110, \dots, 150$ $\lambda = 10^{-12}, 10^{-10}, \dots, 10^{-6}$ $I = 200, 300, 400$

表3 小規模データセットにおける平均絶対値誤差 (MAE) と平均二乗平方根誤差 (RMSE)

Table 3. Mean absolute error and root mean squared error for small dataset.

	MLP	SVR	RBFN
MAE (W)	8.6	3.9	3.9
RMSE (W)	20.2	15.0	11.8

に対して、エアコンの消費電力推定を行ったところ、表3の結果を得た。このときの各パラメータの値は、

MLP: $n = 14$, $\eta = 0.2$, $\alpha = 1.0$, $M = 0.2$,

SVR: $C = 20$, $\gamma = 0.07$,

RBFN: $m = 30$, $\lambda = 10^{-6}$, $I = 400$

である。

表3より、MLPの平均絶対値誤差 (Mean Absolute Error 以下、MAE) および平均二乗平方根誤差 (Root Mean Squared Error 以下、RMSE) が、SVR および RBFN の誤差よりも2倍ほど大きい。つまり、MLPの消費電力推定能力は、他の2つの手法より劣っていることがわかる。

また、SVRとRBFNのMAEは一致しており、この視点からは、SVRもRBFNも同等の消費電力推定能力を有していると見ることができる。しかし、大きな誤差を厳しく評価するRMSEについてSVRおよびRBFNを比較してみると、SVRの値よりRBFNの値が小さくなっており、RBFNの方が大きな誤差を出さない、つまり、大きくはずれないことがわかる。

図3に検証用データに対する各手法の推定消費電力と実績消費電力との関係を示す。ここで、横軸は実績消費電力 (measurements) を表し、縦軸は推定消費電力 (estimates) を表す。実績消費電力と推定消費電力が全ての点で一致していれば、傾き1の直線がグラフ上に生成されることになる。また、図中、上実線と下実線の間は、定格消費電力からのずれ $\pm 10\%$ の領域を表す。この領域外に、推定消費電力の値がどの程度存在するかで、推定能力を評価する。

これらの図より、MLPによる推定消費電力が、定格消費電力に対する $\pm 10\%$ の領域に入らない場合が多いことが分かる。SVRによる推定消費電力は、100Wから300Wの間では、RBFNの結果よりも定格消費電力に対する $\pm 10\%$ に近い様子が分かる。しかし、400Wから500Wの領域では、消費電力をRBFNより遥かに低く推定している点が数点存在している。このことが、表3で示した結果を生成している原因である。

〈4・3〉 大規模データに基づくエアコンの消費電力推定
上述の実験結果より、消費電力推定においてSVRおよびRBFNのMLPに対する優位性は確認できた。ここでは、SVRとRBFNの示した結果が、小規模で特異なデータに対する特性ではないことを確認するため、大規模なデータに基づく、インバータエアコンの消費電力推定結果について報告する。

本消費電力推定実験では、観測された11,636点のデー

〈4・1〉 モデル選択 各機械学習手法の消費電力推定能力を比較するためには、表現力が十分にあると同時に、複雑過ぎないモデルを見つける必要がある。以下では、実験結果を比較するモデルのパラメータをどのように決めたかについてまとめる。

本論文で比較したMLPは、中間層のユニット数 n 、学習率 η 、シグモイド関数の傾き α 、モーメント項の係数 M というパラメータを有する。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⁽⁷⁾。

SVRは、3.で述べた ϵ チューブのさらに外側の点をどの程度まで考慮するかを決定する正則化パラメータ C を有している。さらに、非線形のマッピング $\phi(\cdot)$ を意味する核関数を決める必要がある。本実験では、電気機器のON/OFF推定問題に適用した際の知見⁽⁴⁾から、次式で与えられるRBF核関数⁽⁶⁾を適用した。

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\gamma \|\mathbf{x} - \mathbf{y}\|^2) \dots \dots \dots (12)$$

このRBF核関数はその分布の幅を決めるパラメータ γ を有している。つまり、パラメータ γ により分類の精度 (粒度) を変えることが可能となっている。

また、RBFNが有するモデルのパラメータは、RBFの中心 (中間層ユニット) 数 m 、正則化パラメータ λ と繰り返し最適化の回数 I である。

本論文では、SVRおよびRBFNのパラメータを10-fold cross validationで決定した。本実験でのパラメータの稼働範囲を表2に示す。

〈4・2〉 小規模データに基づくエアコンの消費電力推定
ここでは、2.の小規模データに基づく、インバータエアコンの消費電力推定結果について報告する。

本消費電力推定実験では、観測された1,827点のデータを、学習データ点500と検証用データ点1,327に分けた⁽⁷⁾。この学習データを各機械学習手法に適用し、検証用データ

図3 小規模データでの推定消費電力と実績消費電力との関係 上:MLP 中:SVR 下:RBFN
Fig.3. The relationship between the estimated power consumption and the actual power consumption for the small dataset. top:MLP middle:SVR bottom:RBFN.

タを、学習データ点3,000と検証用データ点8,636に分けた。この学習データをSVRとRBFNに適用し、検証用データに対して、エアコンの消費電力推定を行ったところ、表4の結果を得た。このときの各パラメータの値は、

SVR: $C = 100$, $\gamma = 0.03$,

RBFN: $m = 130$, $\lambda = 10^{-10}$, $I = 200$

である。

表4より、SVRとRBFNのMAEはほぼ一致しており、大きな誤差を厳しく評価するRMSEについては、SVRの値よりRBFNの値が小さくなっている。この結果は小規模データに対する結果と一致しており、RBFNの優位性は、特異なデータに依存するものではないことがわかる。

図4に検証用データに対する各手法の推定消費電力と実績消費電力との関係を示す。

表4 大規模データにおけるMAEとRMSE

Table 4. Mean absolute error and root mean squared error for large dataset.

	SVR	RBFN
MAE (W)	6.3	6.1
RMSE (W)	13.4	10.7

図4 大規模データでの推定消費電力と実績消費電力との関係 上:SVR 下:RBFN

Fig.4. The relationship between the estimated power consumption and the actual power consumption for the large dataset. top:SVR bottom:RBFN.

SVRによる推定消費電力は、200W付近から600W付近の間では、SVRの推定消費電力もRBFNの推定消費電力もほぼ同じ結果を示している。しかし、600W付近から800Wの領域では、SVRが消費電力をRBFNより遥かに低く推定している点が数点存在している。

これらの結果は、前述の小さいデータに対する結果と一致しており、最も消費電力推定に適している、つまり、平均的な推定誤差が小さく、かつ大きな推定誤差が少ない手法がRBFNであることを示唆している。

〈4・4〉実験結果の考察 本節では、比較した機械学習手法のどのような特性に起因して、本章で報告した実験結果が現れたのかを考察する。

MLPは、シグモイド関数の重ね合せで任意の連続関数(ここでは、高調波パターンを入力とし、エアコンの消費電力を出力とする関数)を近似することができる。しかしMLPは、式(3)からもわかるように学習データ点が全て

文 献

- (1) C. M. Bishop: "Neural Networks for Pattern Recognition", Oxford University Press (1995)
- (2) D. S. Broomhead et al.: "Multivariable functional interpolation and adaptive networks", *Complex Systems*, Vol.2, pp.321-355 (1988)
- (3) W. Hart: "Non-intrusive appliance load monitoring", *Proc. IEEE*, Vol.80, No.12 (1992)
- (4) T. Onoda et al.: "Experimental analysis of support vector machines with different kernels based on non-intrusive monitoring data", *IJCNN'02*, 1010, Honolulu, USA (2002)
- (5) D. E. Rumelhart et al.: "Learning Internal Representations by Error Propagation", *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol.1, pp.318-362, Bradford Books/MIT Press, Cambridge, MA. (1986)
- (6) V. N. Vapnik: "The Nature of Statistical Learning Theory", Springer (1995)
- (7) K. Yoshimoto et al.: "Neural Networks Applied to Non-Intrusive Load Monitoring System", *T.IEE Japan*, Vol.122-C, No.8, pp.1351-1359 (2002-8) (in Japanese)
由本勝久・他:「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」, 電学論 C, 122, 8, pp.1351-1359 (2002-8)

村 田 博 士 (非会員) 1969年2月24日生。1993年3月東京理科大学基礎工学研究科電子応用工学専攻修士課程修了。同年4月(財)電力中央研究所入所。現在に至る。主として画像処理および学習アルゴリズムの適用研究に従事。

小野田 崇 (非会員) 1962年10月27日生。1986年3月国際基督教大学教養学部理学科卒業。1988年3月東京工業大学理工学研究科原子核工学専攻修士課程修了。同年4月(財)電力中央研究所入所。現在に至る。主として学習アルゴリズムの開発、学習アルゴリズムの数理的側面の研究、および学習アルゴリズムの適用研究に従事。1996年度人工知能学会論文賞受賞。博士(工学)。

由 本 勝 久 (正員) 1967年7月15日生。1996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)電力中央研究所入所。現在に至る。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。博士(工学)。

中 野 幸 夫 (正員) 1957年3月4日生。1981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。現在、同研究所需要家システム部上席研究員。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。1995年2月~96年1月米国ローレンスバークレー国立研究所エネルギー磁環境部客員研究員。博士(工学)。

同じ存在確率を有するという経験分布を用いて学習を行うので、データ点の密度が高い領域を学習する傾向が強い。そのため、データ点の密度が疎な領域の学習が苦手である。図3を見てもデータ点の多い0Wから100Wの間、および350Wから500Wの間の領域では、消費電力を推定できていることがわかる。しかし、データ点の少ない100Wから350Wの間の領域では相違が大きい。一方、SVRやRBFNは、式(5)や式(11)のように損失関数にモデルの複雑さを制御する項を持つため、学習データの分布を考慮できる。以上の特性から、MLPは、SVRおよびRBFNより推定能力の低くなると考えられる。

SVRとRBFNを比較した場合、MAEによる評価はほぼ同等であるが、大きな誤差を厳しく評価するRMSEによる評価では、RBFNの方がSVRの能力よりも優れているという結果になった。SVRは、式(6)で表現される誤差を小さくするように学習を行う。式(6)より、SVRでは、実際の消費電力 y_i と、学習する連続関数 $f(x_i)$ との絶対値距離を最小化していることがわかる。つまり、学習データ全体で消費電力 y_i と、学習する連続関数 $f(x_i)$ との絶対値距離の平均が小さくできれば、ある程度大きな誤差が存在しても、それを考慮しない。一方、RBFNが学習によって最小化する損失関数は、式(11)で表現される。これより、RBFNでは、実際の消費電力 y_i と、学習する連続関数 $f(x_i)$ との二乗距離を最小化していることがわかる。つまり、RBFNでは、大きな誤差を強調させ、その誤差をできるだけ小さくするように学習が進む。このSVRとRBFNの損失関数の相違が、実験に現れた特性の原因であると考えられる。

5. ま と め

家庭の引込線付近で計測した情報のみを用いて、家庭内におけるインバータ機器の消費電力推定を行う問題に対し、数種の機械学習技術を適用して、機械学習技術の消費電力推定における能力を評価した。

本報告で述べた実験による主な結果は次の3点である。

- (1) インバータ機器の代表であるエアコンのように、消費電力にばらつきが大きい電気機器の消費電力推定には、ニューラルネットワークを適用するより、SVRやRBFネットワークを適用する方が妥当である。
- (2) 平均絶対値誤差で評価が行われる場合、SVRとRBFネットワークは同等の能力を有する。
- (3) 平均二乗平方根誤差で評価が行われる場合、RBFネットワークの推定能力は、SVRの推定能力より優れている。

以上の結果より、家庭内電気機器消費電力推定には、RBFネットワークが最も適していることがわかった。

今後は、モニタリングシステムへのRBFネットワークの実装を検討していく。

(平成14年7月10日受付, 平成15年2月21日再受付)