

# 屋外からの家庭内電気機器の消費電力推定

村田 博士 小野田 崇

(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

{murata,onoda}@criepi.denken.or.jp

概要：本論文は、電気機器の使用実態を、家庭内に立ち入ることなしに、精度よく推定する手法の開発の一環として、家庭への引込線入り口付近で計測したデータを用いて、複数の電気機器が稼動している状況下で、各電気機器の消費電力の推定を行うのに最も適した機械学習手法を明らかにする。非線形連続関数近似に利用される代表的な機械学習手法であるニューラルネットワーク、サポートベクター回帰法、RBF ネットワークをインバータエアコンの消費電力推定に適用し比較検討を行う。

## 1 はじめに

お客様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、お客様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。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お客様に負担を強い等の問題点も多い。このため、工事やコスト、お客様への負担等が極力小さい方法、つまり、家庭内へ入ることなく、各電気機器の使用実態を測定できる、屋外にある引込線入り口付近での測定で得られる情報のみから、家庭内の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。

これまでに、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が、オンかオフかを高精度に同定する手法を開発しており [4]、さらなるお客様への詳細なサービス提供には、電気機器のオン・オフの情報以上に、稼動中の電気機器個々の消費電力量の情報が必要となる。そこで、稼動中の電気機器個々の消費電力量の推定を行う手法の開発が望まれている。

以上のような背景から、総負荷電流の基本波成分および高調波成分を用いて、下流に接続されている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ニューラルネットワーク (Multi-Layered Perceptron 以下、MLP)、サポートベクター回帰法 (Support Vector Regression 以下、SVR)、RBF ネットワーク (Radial Basis Function Network 以下、RBFN) を適用し、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り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

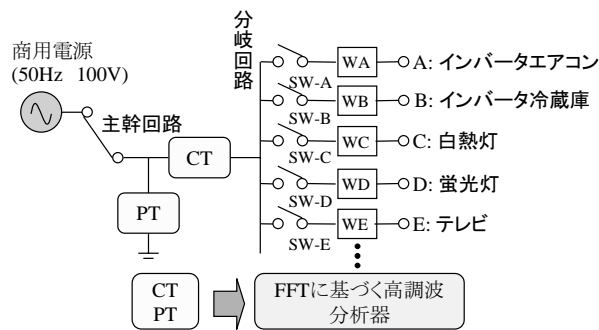


図 1: 測定回路

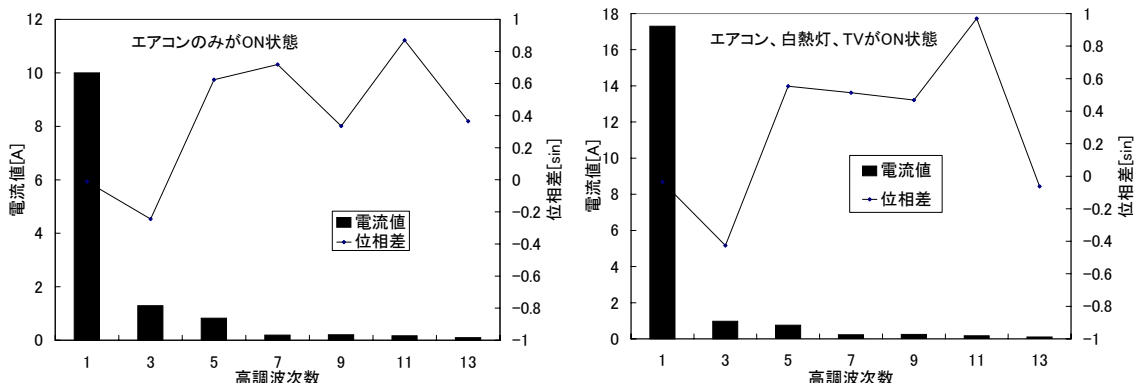


図 2: 高調波パターン例 左: インバータエアコンのみが稼働している状態 右: インバータエアコン、白熱灯、テレビが稼働している状態

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。

この測定装置を使って、測定されたデータ例を図 2 に示す。棒グラフが各次数での電流値を表し、折れ線が各次数での位相差を表す。図 2 の左図はインバータエアコンのみが稼働している状況、右図はインバータエアコン、白熱灯、テレビが稼働している状況での基本波成分および高調波成分のパターンを示している。比較すると、電気機器の増加により電流値の絶対値が増加する他に、位相差に違いがあることが確認できる。このように高調波成分パターンは電気機器の稼働状態との関係が深く、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 左に示す 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。

**大規模データ** 測定対象電気機器数を表 1 右の 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 3 に MLP, SVR, RBFN を用いた電気機器消費電力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。

表 1: 測定に使用した電気機器

小規模データ			大規模データ		
記号	電気機器	最大消費電力	記号	電気機器	最大出力
A	インバータエアコン	1000W	A	インバータエアコン 1	1000W
B	インバータ冷蔵庫	150W	B	インバータエアコン 2	1000W
C	白熱灯	100W×6	C	扇風機	100W
D	蛍光灯	20W×6	D	白熱灯	50W×5
E	テレビ	80W	E	蛍光灯	40W×5
			F	インバータ蛍光灯	50W×5
			G	テレビ 1	65W
			H	テレビ 2	80W
			I	電気ポット	100W
			J	冷蔵庫	150W




図 3: 稼動電気機器消費電力数推定システムの概略

### 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, 5]。

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、 $z_j$  を出力と見ることができる。

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、 $\frac{\partial E^n}{\partial w_{ji}} = \frac{\partial E^n}{\partial a_j} \frac{\partial a_j}{\partial w_{ji}} = \epsilon_j z_i$  となり、加重の修正は

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

で行われる。

$\epsilon$  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

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

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。

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




図 4: SVR の概念図: SVR では, 精度  $\epsilon$  は事前に決定され, データは半径  $\epsilon$  のチューブにフィットされる.

### 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  $\epsilon$ -SVR と呼ばれるアルゴリズム [6] は次の関数を推定する.

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

このとき, 学習は次の損失関数を最小化することで行う.

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

$\|\mathbf{w}\|$  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,  $R_{emp}^\epsilon[f]$  は次式で表現される.

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

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.  $\zeta^*$  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. 図 4 に SVR の概念図を示す.

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.

$$\text{maximize } W(\alpha, \alpha^*) = -\epsilon \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) + \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) y_i - \frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) (\mathbf{x}_i \cdot \mathbf{x}_j) \quad (7)$$

$$\text{subject to } \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i^{(*)} \in [0, \frac{C}{\ell}] \quad (8)$$

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.

$$\text{maximize } W(\alpha, \alpha^*) = -\epsilon \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) + \sum_{i=1}^{\ell} (\alpha_i^* + \alpha_i) y_i - \frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) k(\mathbf{x}_i, \mathbf{x}_j) \quad (9)$$

### 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．

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

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．Radial basis function は関数の一つの特異なクラスである．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  $g(\mathbf{x}) = \phi((\mathbf{x} - \mu)^\top \mathbf{R}^{-1}(\mathbf{x} - \mu))$  となる．ここで， $\mu$  は中心を表し， $\mathbf{R}$  は計量を表す．関数  $\phi$  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  $\mu$  と半径  $\sigma$  である．この Gaussian 関数は局所的，つまり，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．

RBF ネットワークの損失関数は，以下の式のようになる．

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

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章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．

### 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．

本報告で比較した MLP は，中間層のユニット数  $n$ ，シグモイド関数の傾き  $\alpha$  というパラメータを有する．SVR は，3章で述べた  $\epsilon$  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．このパラメータ  $C$  を特定する必要がある．また，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．

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

この RBF 核関数はその分布の幅を決めるパラメータ  $\gamma$  を有している．つまり，パラメータ  $\gamma$  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  $\lambda$  と繰り返し最適化の回数  $I$  である．

上述より，MLP，SVR および RBF ネットワークを適用するには，2 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．本報告では，各機械学習手法のパラメータを 10-folds cross validation で決定した．また，本実験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章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．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．

表 2: 各パラメータの稼働範囲

小規模データの場合		大規模データの場合	
手法	パラメータ	手法	パラメータ
MLP	$n = 3, 4, \dots, 15$ $\alpha = 1.0$	SVR	$C = 10, 20, 50, 100, 200, 500$ $\gamma = 0.01, 0.02, \dots, 0.07$
SVR	$C = 10, 20, 50, 100, 200, 500$ $\gamma = 0.01, 0.02, \dots, 0.07$	RBFN	$m = 100, 110, \dots, 150$ $\lambda = 10^{-12}, 10^{-10}, \dots, 10^{-6}$
RBFN	$m = 10, 20, 30, 40$ $\lambda = 10^{-7}, 10^{-6}, 10^{-5}, 10^{-4}$ $I = 200, 300, 400$		$I = 200, 300, 400$

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)

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

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 の誤差よりも約 2 倍大きくなっている。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, 大はずれしないことがわかる。

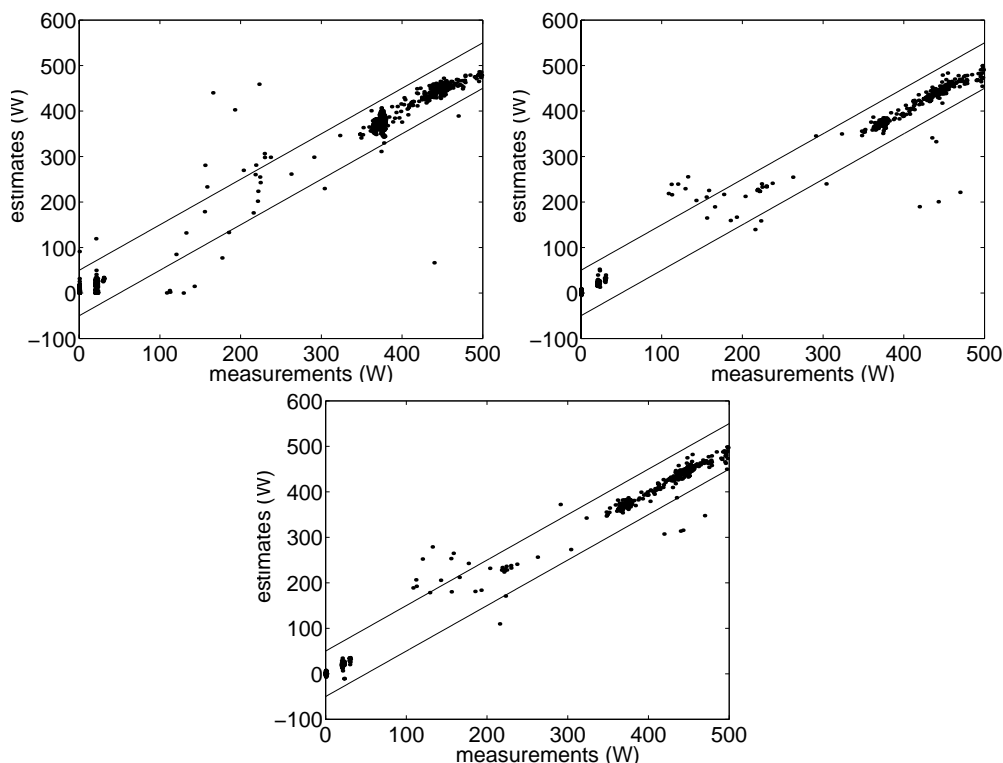


図 5: 小規模データでの推定消費電力と実績消費電力との関係 上左: MLP 上右: SVR 下中: RBFN

図 5 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。ここで, 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。

表 4: 大規模データにおける MAE と RMSE

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

表 4 より、SVR と RBF ネットワークの 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 6 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。




図 6: 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 左: SVR 右: 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) からわかるように学習データ点が全て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 5 を見てもデータ点の多い 0W から 100W の間、および 350W から 500W の間のが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

ロードサーベイの立場から家庭の引き込み線付近で計測した総負荷カーブのみを用いて、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。

## 参考文献

- [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* 2, 321–355, 1988.
- [3] W. Hart.: *Non-intrusive appliance load monitoring*. *Proceedings of the IEEE*, vol. 80, no. 12, 1992.
- [4] T. Onoda et al.: *Applying Support Vector Machines and Boosting to a Non-Intrusive Monitoring System for Household Electric Appliances with Inverters*. NC'2000, 2000.
- [5] D. E. Rumelhart et al.: *Learning Internal Representations by Error Propagation*. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 1: Foundations, 318–362, Bradford Books/MIT Press, Cambridge, MA., 1986.
- [6] V. N. Vapnik.: *The Nature of Statistical Learning Theory*. Springer, 1995.