

[研究論文]

家電内センサを 活用した消費電力予測の研究

宮澤重明¹・志田匠²・杉村博¹

1 博士前期課程電気電子工学専攻

2 創造工学部ホームエレクトロニクス開発学科

Predicting Electricity Consumption with Sensors of Home Appliances

Shigeaki MIYAZAWA¹, Takumi SHIDA², Hiroshi SUGIMURA¹

Abstract

Home Energy Management System, HEMS for short, is expected to conserve electric power. In order to realize appropriate energy management and device control by HEMS, it is important to predict future behavior of electricity consumption. Typically, the method of future prediction of electricity consumption is built by using a combination of machine learning and environmental data which is acquired by sensor network. Considering to apply the method to HEMS, we point out that it is difficult to build such a network into a general residence. We thus propose a method to use network-connected home appliances as a sensor network. Environmental data is collected by the network which is composed by ECHONET Lite protocol. Finally, our system outputs models for future prediction of electricity consumption by using machine learning.

Keywords: HEMS, ECHONET Lite, machine learning, electricity consumption

1. はじめに

近年、生活スタイルの多様化や生活水準の向上により、世帯当たりの消費電力量は増加傾向である^[1]。そこで無駄な消費を減らし、かつ快適な生活を実現するシステムとして Home Energy Management System (HEMS) に注目が集まっている。HEMS はエネルギー管理システムであり電力消費を節約することになっているが、効率的なエネルギー管理をしていない。この効率的なエネルギー管理とは一般家庭に設置される蓄電池の最適な充放電などの機器の制御を行うことである。そして、このエネルギー管理は電力の需要予測が重要であり、先行研究によると予測手法には機械学習を用いることが有用だとされている^{[2][3][4]}。

電力会社などの大規模発電施設では翌日や数時間後の需要電力量の予測を行い、出来る限り無駄な発電を避け、予備力の最小化を行っている。予測には過去の需要電力量や天気、温度といった環境データが重要であり、それら膨大に蓄積されたデータを分析して予測を行っている。そのため文献[2]のようにニューラルネットワークの手法

を用いた消費電力の予測が典型的に行われている。しかし、この手法は一般家庭に適用するには難しい。原因として大規模発電施設の電力量は一般家庭や企業、工場などの複合的要因から成り立っているため、発電施設の過去の発電量などの実績データを一般家庭に用いることは出来ない。さらに、一般家庭は温度だけではなく、人の在宅状況によって消費電力量が変化する。よって文献[2]の予測手法を単純に一般家庭へ適用することは難しい。

一般家庭を対象とした研究として翌日の最大電力予測手法が提案されている^[3]。この研究では近隣の気象情報と過去の消費電力情報を用いた最大電力の予測を行っている。予測手法として重回帰モデルを作成することにより、取得した環境データと過去の消費電力から最大消費電力の予測を行っている。しかし、家庭内のエネルギー管理を行う場合は最大電力値ではなく、数時間後などの使用電力の推移を把握することが重要である。

文献[4]では短期電力需要予測を行うことで数時間後の消費電力量の予測を可能にした。データは室内にセンサノードを設置して学習データの温度や湿度、人感センサを収集している。予測手法を適用するには学習データが

必要であり、室内にデータの収集システムを導入しなければならない問題がある。そこで予測システムを一般家庭への導入を想定し、新しいセンサを設置せずに簡易的にデータ収集が可能な方法を検討する。

2. 予測に用いるデータ収集方法の提案

消費電力予測手法にはニューラルネットワークや、時系列データを扱うことが出来るリカレントニューラルネットワーク (RNN) が用いられている。RNN は連続的な情報を学習することが得意であるため、温度や湿度、消費電力量などの時間によって変化する値を学習する方法として適している。Fig. 1 に RNN のモデル作成方法を示す。消費電力の予測値を得るには、モデルの作成が必要であり、モデル作成には学習データを使用する。作成されたモデルは学習データと同じ要素を入力することで予測値を出力することが出来る。先行研究によると消費電力予測手法では学習データとして温度、湿度、人感センサを用いることで予測精度の高いモデルが作成可能だとわかっている^[4]。

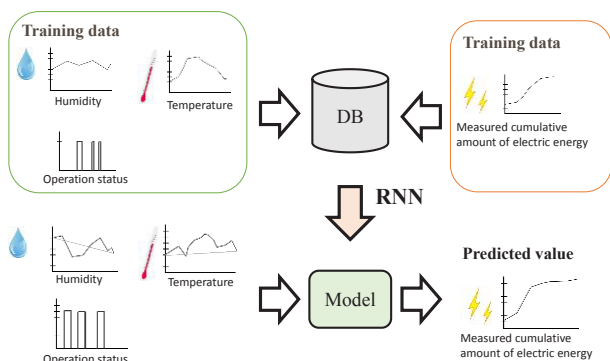


Fig. 1 機械学習によるモデル作成

従来、これらの学習データは、室内にセンサネットワークを構築して取得していた^[4]。室内に新たにセンサを設置することは、電源の確保や、設置者の情報技術の知識を必要とし、さらに居住空間の美観を損なう。このような理由から、センサを設置することは消費電力予測システムを一般家庭に導入する妨げになっている。そのため、我々は新たにセンサを室内に配置せずに、センサネットワークを構築する方法として家電製品内のセンサを活用することを提案する。

3. データ収集システムの構築

消費電力の予測手法を行うには、環境データなどの学習データと、消費電力値の教師データが必要である。先行研究ではセンサノードを部屋に配置し、環境データの取得している^[4]。本システムでは家電製品内のセンサでセンサネットワークの構築し、環境データを収集する。さらに教師データである消費電力値の収集も同時に行う

システムを開発する。

3.1. 要求仕様

本研究で使用するデータ取得システムは、要求仕様として以下の3つを満たす必要がある。

1. 室内の環境データを取得する機能
2. 消費電力に関するデータを取得する機能
3. 家電機器の動作状態を取得する機能

要求1は新たにセンサを室内に配置することなく家電製品内のセンサ情報を活用し、室内の環境データを収集する。要求2は予測対象である消費電力量などのデータを取得する。要求3は機器の動作によって消費電力値は大きく変わるため、家電機器の動作状態のデータを取得する。

3.2. データ収集方法

本システムは環境データを家電機器内のセンサで取得する。家電機器のセンサ情報を取得するには ECHONET Lite (ISO/IEC 14543-4-3、以下 EL) を用いる。EL に対応した機器はネットワーク経由で、機器の動作状態の操作や、動作状態を取得することが出来る。消費電力値も EL の規格に従ってデータを取得する。Fig. 2 にデータ取得システムのシーケンス図を示す。コントローラは EL 機器に対して取得可能なデータを確認する。その後、取得可能なデータは EL 機器に対して5分間隔で取得を行う。データベースに保存する際は、日時などを付属データと共に保存する。

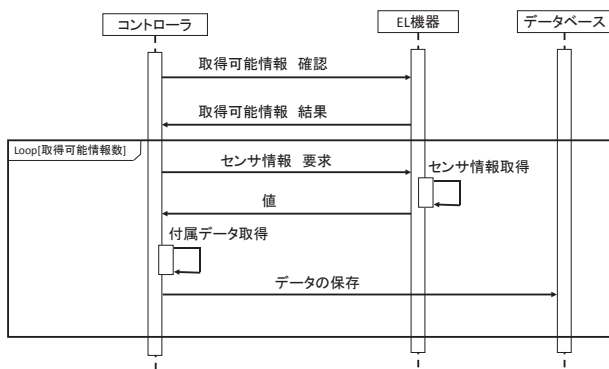


Fig. 2 センサ情報取得システムのシーケンス

3.3. 実装

Fig. 3 に実装したセンサ情報取得システムを示す。取得に使用する機器はエアコンと空気清浄機、分電盤メータである。各機器はネットワークに接続された機器であり EL 通信が可能である。エアコンからは動作状態と湿度、温度を取得し、空気清浄機からは動作状態を取得する。これらのデータの取得は5分間隔で行い、データベースは MySQL を使用した。表1に保存するデータの構成を示す。データベースには日時と EL パケット情報、送信先 IP、受け取り IP の情報が記録される。

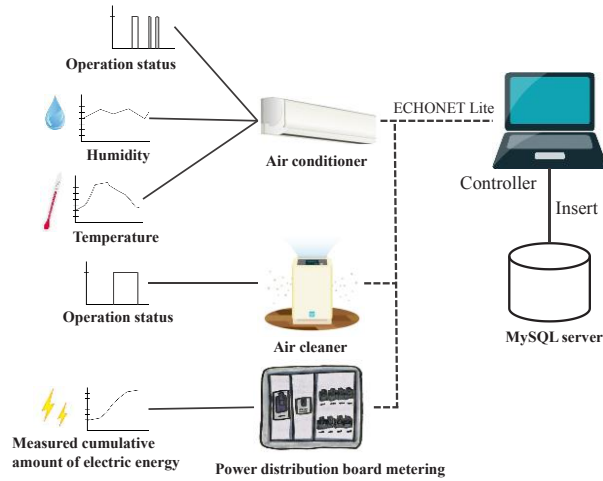


Fig. 3 センサ情報取得システム

このシグモイド関数に適応するために各値を標準化する必要があります。0 から 0.9 の値に変換する。家電機器などの動作状態のような ON と OFF からなるデータは 0.1 と 0.9 で数値化した。データの整形後は CSV ファイルとして出力する。なお、学習モデルの評価に用いる未学習データも同様に処理する。

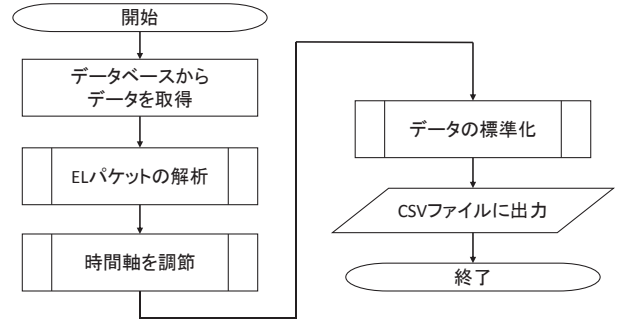


Fig. 4 データ成形のフローチャート

Table 1 データの構成

日時	ELパケット情報	送信先 IP	受信先 IP
2016-09-20 2:20:20	1081361001300105f017201800131	192.168.0.9	192.168.0.36
2016-09-20 2:20:21	1081361001300105f017201ba0150	192.168.0.9	192.168.0.37
2016-09-20 2:20:22	1081361001300105f017201bb011a	192.168.0.9	192.168.0.38
2016-09-20 2:20:23	1081361001350105f017201800130	192.168.0.21	192.168.0.39
2016-09-20 2:20:24	1081361002870105f017201c004004ecf88	192.168.0.6	192.168.0.40

4. 収集データによる消費電力予測

消費電力予測の手法には温度や湿度、機器の動作状態の時系列データを適用させる。本システムで蓄積したデータはそのまま機会学習の学習データに使用できない。そのため、取得したデータは時間軸を合せるなどのデータ整形を行う。その後、RNN を用いた消費電力予測のモデルの作成と、予測結果を考察する。

4.1. データの整形

取得したデータは消費電力予測手法に適用させるために、データの整形をして学習データにする。Fig. 4 に学習データ作成のためのフローチャートを示す。データベース上のデータは EL のパケット情報になっているため数値化を行う。解析を行うためには EL プロトコルに従うため Appendix Release H を参照する^[5]。さらに取得したデータは機器のレスポンスの差があるため取得時間が異なる。そのため、機械学習に用いるために学習データは時間軸をあわせる必要がある。時間軸を合せる方法は線形の傾きを計算して目的時間の値を導き出す。エアコンや空気清浄機の動作状態の ON もしくは OFF の場合は時間軸に対して、前の状態を維持するようにした。機会学習に用いる活性化関数は式 (1) のシグモイド関数を使用する。

$$s(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

4.2. 機械学習によるモデルの作成

Fig. 5 に予測に用いる RNN の模式図を示す。RNN の構成は入力層に 6 ユニット、隠れ層 10 ユニット、出力層 1 ユニットのエルマンネットワーク型に設置した。RNN には現在時刻と温度、湿度、エアコンの動作状態、空気清浄機の動作状態、現時刻の積算電力量を入力し、教師データとして 1 時間後の消費電力量の値で学習した。本来、消費電力予測のモデル作成では、現時刻を学習データとして使用しない。なぜならば、季節ごとに時間に対する扱いが同じでないためである。例えば、冬の 13 時と夏の 13 時では夏の方が冷房を使う確立が高く、逆に冬は暖かいため暖房器具を使用されない。そのため、季節ごとの消費電力値が同時刻で異なるため一般的には使用されない。今回のモデル作成では学習する期間は短いため、季節の影響に作用されないと考え現時刻を学習データとして用いる。

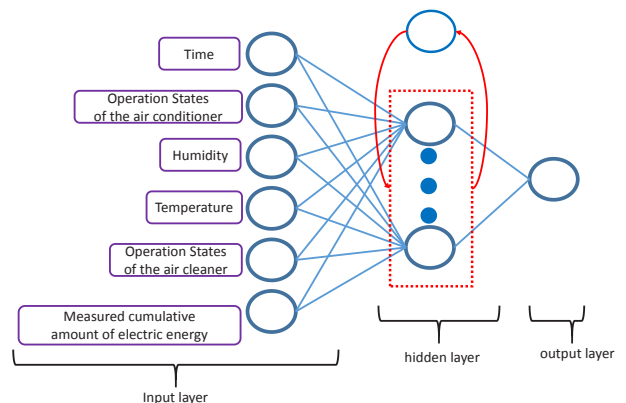


Fig. 5 RNN の模式図

4.3. 予測結果

2016 年 6 月 25 日から 2016 年 9 月 6 日で得られたデータから、1 時間後の室内消費電力を予測するモデルを作

成する。RNN の入力層に 6 種類のデータを入力し、学習を 50 回行い、モデルを作成した。作成したモデルは 2016 年 9 月 10 日から 2016 年 9 月 13 日の 4 日間の未学習データを用い予測精度を検証した。データの取得場所は作業部屋であり、複数人が出入り出来る部屋である。常時、人が作業を行う部屋ではなく、部屋の使用頻度は不規則である。Fig. 6 に予測結果と実データの積算電力量のグラフを示す。

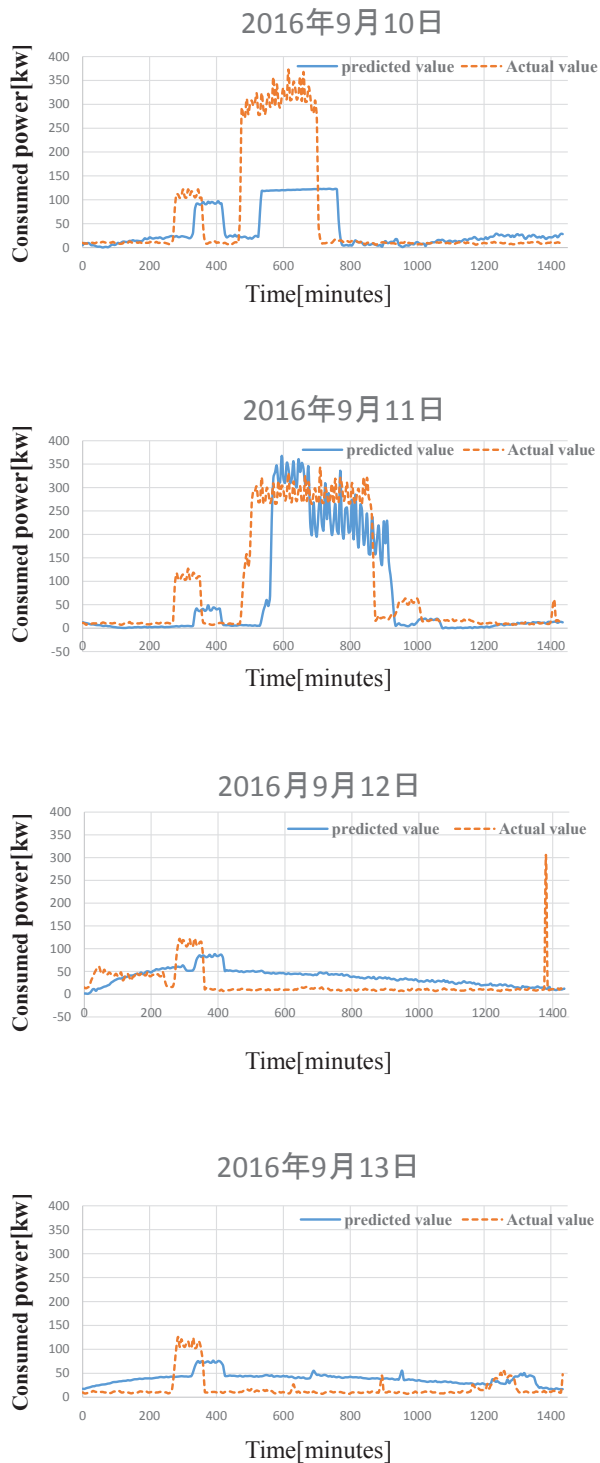



Fig. 6 予測結果

4.4. 考察

今回行った手法では予測精度に課題が残った。原因として、対象となる部屋の使用頻度が低かったため機器の動作状態の変化がなかったことがあげられる。Fig. 7 にモデルに入力した未学習データを示す。大きな変化を示しているのは、積算電力量だけである。Fig. 6 の予測した消費電力値と実際の消費電力値の波形を見比べると、入力された積算電力の値を一時間後の予測値として近い値を出力していることがわかる。これより、今回作成したモデルは入力された積算電力量の値と予測値は強い相関関係になっている。今回のように使用頻度が低い部屋では、隠れ層の数をさらに低くした方がより正確なモデルが作成できると考えられ、今後の検証が必要である。






Fig. 7 未学習データ

5. まとめ

本研究ではデータ収集システムの構築と、収集した環境データより機械学習による室内消費電力の予測手法を適応させて評価した。データ収集システムには EL 通信を活用してセンサネットワークを構築した。EL 対応した家電機器内のセンサを活用することで、従来のように新たにセンサを室内に配置することなく、消費電力予測のための環境データを収集することが出来た。これにより消費電力予測の学習データを容易に収集することを可能にした。さらに、取得したデータを用い消費電力の予測手法を適用させた。作成したモデルは実測値と予測値に誤差があり学習に関しては課題が残った。原因としては入力した学習データの変化があまりないため、特徴抽出が困難であったと考えられる。そのため、動作状態を取得できる機器を増やすことによって、予測精度の向上が期待できる。

参考文献

- [1] 電気事業連合会, 原子力・エネルギー図面集 2015 p1-2-13 (2015)
- [2] 飯坂 達也, 松井 哲郎, 福山 良和: 構造化ニューラルネットワークの新しい学習法と最大電力需要予測への適用, 電気学会論文誌 B (電力・エネルギー部門誌), Vol.124, No. 3, pp.347-354 (2004)
- [3] 紺野剛史, 高橋悟, 北島弘伸, 寺西佑太, 園田俊浩: 事業所タイプにおける需要予測手法の評価, 研究報告コンシューマ・デバイス&システム (CDS), Vol. 2013-CDS-6, No. 5, pp.1-6 (2013)
- [4] 市川昌宏, 向井政貴, 西尾信彦: 家庭内生活パターンを考慮した電力需要予測手法, 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2012-UBI-36, No. 17, pp.1-5 (2012)
- [5] APPENDIX ECHONET 機器オブジェクト詳細規定 Release H
https://echonet.jp/wp/wp-content/uploads/pdf/General/Standard/Release/Release_H_jp/Appendix_H.pdf (2016)