

HEMS・BEMSの普及に向けた 太陽光発電量予測システムの構築

AE15026 川畑待耶

指導教員 藤田吾郎

1. はじめに

日本のCO₂排出量の推移を見ると、産業部門や運輸部門が減少しているのに比較すると、家庭部門は依然として増加しており、家庭部門の対策を抜本的に計画・実施することが求められている。世帯当たりのCO₂排出量も電気からの排出量が約半分を占めている。そのため、家・ビルそのものの性能向上、家に導入設置されている機器のエネルギー効率向上などが有効とされる。

また、再生可能エネルギーの固定価格買取制度（Feed-in Tariff = FIT）が2012年7月から実施された。FITの実施以降、経済性が改善した太陽光発電の導入が加速している。しかし、2019年11月にはFIT買取期間が終了し始め、政府はFIT買取期間終了に向けた対応が急務となる。

さらに、近年、それぞれの建物ごとに蓄電池を設置し、建物内でエネルギーの最適化を図るサービスに注目が集まっている。こうしたサービスは、電力会社でなくても事業運営できることから、住宅メーカーや建設業者、電機メーカーなど様々な業種の企業が市場参入を狙っている。そのため、蓄電池に対応した住宅向けのエネルギー制御システム「HEMS (Home Energy Management System = 住宅用エネルギー管理システム)」やビル向けのエネルギー制御システム「BEMS (Building Energy Management System = ビル用エネルギー管理システム)」の構築を各社が目指している^[1]。

2. 研究目的

HEMSやBEMSなどが家電機器の遠隔制御、センサーによる自動制御を行うために電力消費量や太陽光発電量の把握が必要となるほか、建物ごとに蓄電池を設置した場合、建物内でエネルギーの最適化を図るためにも、翌日・明後日の太陽光発電量の把握が重要となる。よって、本研究では、太陽光発電量の予測システムを構築することを目的とする。本稿では、発電量予測手法とシミュレーションによる有効性の確認結果について述べる。

3. 発電量予測手法

3.1 計測装置

本研究では、芝浦工業大学豊洲キャンパス内に設置してある太陽光パネルと温度計を用いて2011年から取得している過去の気象データを基に、太陽光発電電力量を事前に予測するシステムの開発を行った。予測に使用する気象要素は気温と日射強度であり、データは1分間隔で計測されているが、汎用性の観点から10分間隔のデータに変換している。また、太陽光パネルの発電容量は10.125kWである。

3.2 ニューラルネットワーク

ニューラルネットワークとは、人の脳で行われている情報処理を模倣した情報処理モデルのことである。教師

あり機械学習の1つで、非線形分離のパターン認識や関数近似を行うことが出来る。図1(左)に示すニューロンモデルが、人の脳細胞をモデル化したものである。これには、他のニューロンから結合荷重をかけて入力された信号を活性化関数に入力して出力する働きがある。図1(右)は、このニューロンを多数組み合わせ、ニューラルネットワークを構築したものである。入力層、中間層、出力層の3層に分かれており、各層の間の結合荷重を更新していくことで正確な出力が行えるように学習する^[2]。

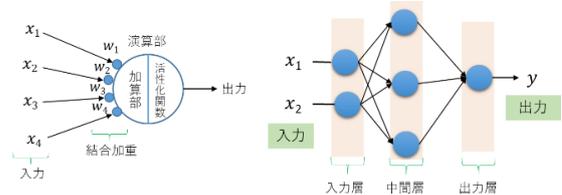


図1 ニューロンモデル(左)とニューラルネットワークの構成(右)

3.3 システム概要

システム概要に関して、構築した流れを基に説明する。

3.3.1 予測部分の構築

ニューラルネットワークの構築には誤差逆伝搬法を用いる。誤差逆伝搬法とはニューラルネットワークを学習させる際に用いられるアルゴリズムである^[3]。

図2は、構築したネットワークである。また、構造に関する詳細を表1に示す。

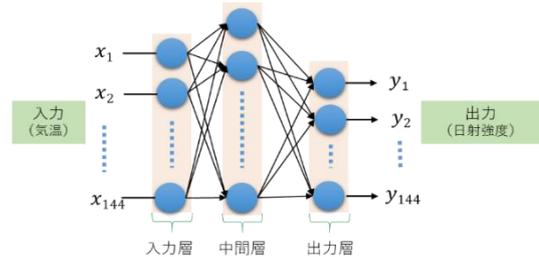


図2 構築したニューラルネットワーク

表1 各層のユニット数

層	ユニット数
入力層	144
中間層(1層)	8000
出力層	144

3.3.2 発電量算出

発電量は、次式によって予測した日射量と太陽光パネルの効率から求めることができる。

$$P_{OUT} = H_A \times P_{AS} \times K \div 1 \dots\dots\dots (1)$$

P_{OUT} : 発電電力量[kWh/日]

H_A : 設置場所での日射量[kWh/(m²・日)]

K : システム損失係数

1 : 標準状態における日射強度[kW/m²]

ただし、標準状態における日射強度 G_s を1kW/m²とする。

3.3.3 予測率の定義

予測した発電量がどの程度一致しているかを表す予測率は次式によって求めることができる。

$$P = \frac{P_{PG}}{A_{PG}} \dots\dots\dots (2)$$

P : 予測率[%]

A_{PG} : 実測発電量[kWh]

P_{PG} : 予測発電量[kWh]

3.3.4 平均相対誤差

予測精度の信頼性を高めるために、予測発電量と実測発電量の相対誤差の平均をとったものを式(3)のように定義した。

$$\text{平均相対誤差[kW]} = \frac{1}{n} \sum_{i=1}^n \frac{|P_i - A_i|}{A_i} \dots\dots\dots (3)$$

$n = 144$: データ数,

P_i : 予測発電電力[kW],

A_i : 実測発電電力[kW]

3.3.5 データの分割

機械学習によるモデルの作成には、準備したデータを学習用データと評価用データの2つに分けて予測モデルの作成、評価を行なうことが一般的である。本研究では7年間分の過去データを学習用データ、最近の1日分のデータを評価用データとする。図3にデータの分割と予測のフローチャートを示す。

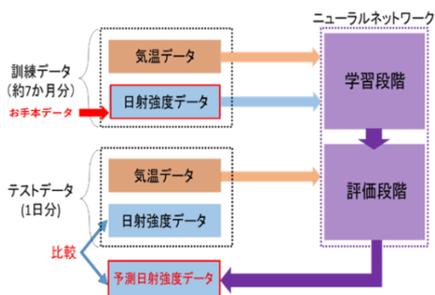


図3 データの分割と予測のフローチャート

5. 結果・考察

開発した発電量予測手法に基づきシミュレーションを行い、翌日の24時間分の予測を行った。評価月は4月と7月とし、それぞれの月の過去データを用いた。図4に学習回数(Epoch)に対する相対誤差を示す。また、図5には、4月の30日分のPV発電量予測を行い、全体を通しての予測精度を示した。さらに図6には太陽光発電量の予測値と実測値の比較結果を示す。また、快晴日だけでなく、日射強度の変動が激しい日のシミュレーションも行うことでこのモデルの予測特性を考察する。

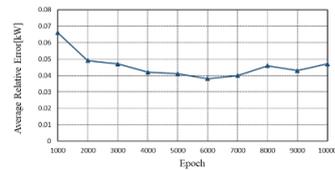


図4 学習回数に対する平均相対誤差

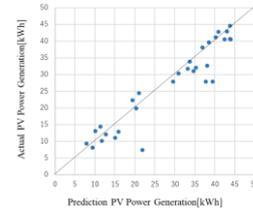


図5 2018年4月のPV発電量予測シミュレーション

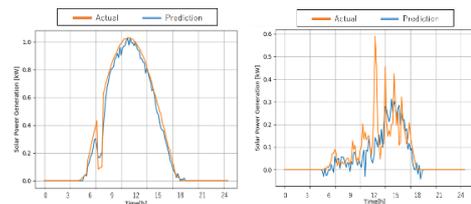


図6 4月の発電量予測結果
(左: 快晴日、右: 雨, 曇りの日)

図4より、学習回数が6000のとき、平均相対誤差時は最小値を示したことから、このモデルの最適な学習回数が明らかになった。図5中の $y=x$ の直線に近いほど予測精度は向上する。また、グラフの右上になるほど快晴日が多く、左下になるほど雨の日が多い。図6より、快晴日の予測精度は95.7%、平均相対誤差は0.010 kWであると判明した。(雨, 曇り)の予測精度は84.2%、平均相対誤差は0.033 kWであると判明した。

6. まとめ

本研究では、ニューラルネットワークを用いた太陽光発電電力予測について研究を行った。シミュレーション結果から、日射強度が大きく変動する雨や曇りの日の予測についてはまだ予測精度に課題を残す。図6快晴日は特に雲の影響を受けづらいことから快晴日のPV発電量曲線が学習段階でしっかりと認識され、予測に乱れが出なかったと考える。雨や曇りの場合においては、多少の発電量の変動には追従できているが、日射強度と気温は比例するわけではないので、発電量の変動が大きい場合には対応できないと考える。今後は実用化に向けたモデルの構築を行う予定である。予測の入力要素に用いる翌日の気温予報データをWebサーバから取得することや、学習用データを自動更新するモデルを目標とする。

参考文献

- [1] A.Yona, T.Senjyu, T.Funabashi, H.Sekine, : “Application of Neural Network to 24-hours-Ahead Generating Power Forecasting for PV System”, *IEEE Trans. Solar Energy*, Vol.128, No.1, pp.33-40, 2008.
- [2] 前田勝紀, : “ニューラルネットワークによる太陽光発電の発電量予測”, 2016, 福井高専研究発表会
- [3] Sebastian Raschka, 株式会社インプレス : “[第2版]Python機械学習プログラミング, 達人データサイエンティストによる理論と実践” 2018