

RBF ネットワークを用いたキャンパスにおける日射量予測

Solar radiation prediction using RBF Network for Campus

羽柴 雄太^{*1}
Yuta Hashiba

浦野 昌一^{*1}
Shoichi Urano

^{*1} 明治大学
Meiji University

In this paper, we propose a prediction method with fewer kinds of data using RBF network for solar radiation prediction on campus. In recent years, the introduction of renewable energy has advanced in Japan, among which the introduction of photovoltaic power generation system is the top. Therefore, for optimal power operation such as small area, it is necessary to predict the amount of solar radiation that affects PV output. We will develop and verify a model that can predict solar radiation amount with high accuracy from past solar radiation performance data in small area. We report the result that we can predict if there is a tendency similar to the past in the prediction model used this time even without weather information, and report that there is a possibility of further improvement in accuracy by adding cloud amount data.

1. はじめに

近年環境問題とともに再生可能エネルギーに注目が集まる中、国内では太陽光発電(Photovoltaic:以下 PV)の導入が最も進んでいる。大規模発電施設以外にも各家庭や事業所単位での導入は現在一般的となっている。ただ太陽光発電には発電量が天候に大きく左右されてしまうといった不安定性があり、大規模導入時には火力発電機の稼働台数にも影響を及ぼす。導入が増えるにつれ系統安定化を図るためにはより精度の高い太陽光発電量予測が必要となってくる。PV の出力は日射量に大きく依存するため太陽光発電量予測は日射量予測と捉えることができる。また、近年ではスマートコミュニティなどの小規模エリアにおける電力の地産地消なども実施されている。そのため需給運用に関する計画や制御を的確に行うためにはコミュニティ単位での予測も重要となってくる。それに加え、2016 年 4 月 1 日の電力の全面自由化により、新電力の小売業への参入が始まり、全ての消費者が電力会社を自由に選択できるようになり電力売買が活発化している。そのため経済的な観点からも効率的な需給運用が必要となる。

2. 日射量の予測

日射量とは、一定の期間に降り注がれる太陽からの光エネルギーである。従来から天気予報・気象衛星データ・衛星画像データなどを用いたいくつかの手法がすでに研究されている。ただ 1 日に発電される電力の総量には大きな変動があり、天候によっては 0kWh になってしまうこともある。こういった観点からその他の再生可能エネルギーの発電量予測や電力需要予測などの予測と比べると不安定な要素が大きい[羽柴 18]。図 1 に明治大学駿河台キャンパスで計測した日射量波形を示す。波形の急降下等から変動が激しいことが分かる。

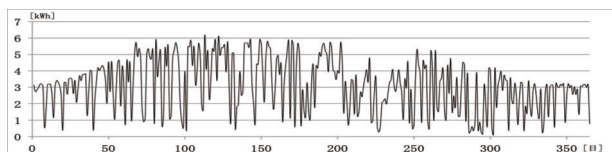


図 1. 明治大学駿河台キャンパス日射量

連絡先: 羽柴雄太, 明治大学大学院先端数理科学研究科,
cs183018@meiji.ac.jp

3. 日射量予測モデルの構築

本稿では、日射量予測モデルに用いるデータは、日射量の実績値と気象データから得られる雲量の実測値を用いる。予測モデルとしてはニューラルネットワークの一種である動径基底関数(Radial Basis Function: 以下 RBF) ネットワークを用いる。

3.1 クラスタリング

RBF ネットワークの予測モデル構築の際、中間層に用いられる重心ベクトルの決定についてクラスタリングに k-means 法を用いる。k-means 法は対象のクラスタの分類と代表ベクトルの再計算を交互に繰り返す。この手法は、(1)式の評価関数 ϕ を最小化するクラスタ中心を見つけることによって、データ X を任意の k 個のクラスタに分割する。

$$\phi = \sum_{x_j \in X} \min_{i \in k} \|x_j - c_i\|^2 \quad (1)$$

但し x_j : 入力データ ($j \in 1 \cdots N$)

c_i : 各クラスタの中心ベクトル

3.2 RBF ネットワーク

RBF ネットワークとは重み付き線形和を用いたニューラルネットワークの手法の一種であり、有限個である入出力データを補完する手法である。基本的な階層型ニューラルネットワークのニューロンの出力関数にシグモイド関数が多く使われるのに対し、RBF ネットワークではガウス関数を用いる。図 2 に示すように入力層、中間層、出力層の 3 層構造となっており、多層パーセプトロンと同じく任意の非線形関数の近似が可能である[森 02]。RBF ネットワークの中間層のガウス関数は(2)式で表現される。

$$h_i(x) = \exp\left(-\frac{\|x - \mu_i\|^2}{2\sigma_i^2}\right) \quad (2)$$

但し x : 入力データベクトル μ_i : 重心のベクトル
 σ_i^2 : 各クラスタ内の分散

本稿では、中間層と出力層間の重みは勾配法により学習を行う。出力層の出力を以下の(3)式に示す

$$y = \sum_{i=1}^M w_i h_i(x) \tag{3}$$

但し x : 入力データベクトル h_i : 中間層の出力
 w_i : 中間層と出力層の結合重み

本稿で用いる RBF ネットワークの中間層のユニット数は、3.1 で示したクラスタリングによって決定する。 σ^2 で表す基底関数の幅は、各クラスタの分散を用いてチューニングすることで決定する。

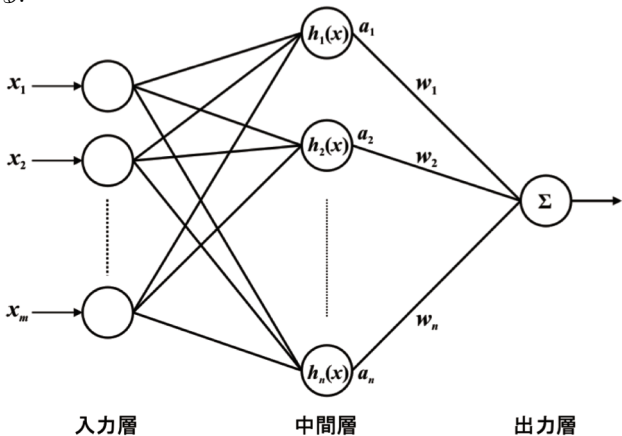


図 2 RBF ネットワークの構造

4. シミュレーション

本稿では日射量予測の対象として明治大学駿河台キャンパスの日射量を予測し、実測値と比べ精度を検証していく。

(1) シミュレーション条件

予測に用いるデータは、明治大学駿河台キャンパスにおける太陽光発電システムの日射量実績データと気象庁が公開するエリアごとの雲量実績データである[気象 18]。日射量実測データは 24 時間分の合計として 1 日の総量を用いた。雲量データは、本来は予測時の予報値を用いるが、今回は長期間のデータセット作成のため現在入手可能である実測値を用いる。実績値は気象庁が公開する実績値のうち日射量の観測地点から最も近い東京地点のデータを用いた。データの期間は、2016 年 1 月 1 日から 2017 年 12 月 31 日の 2 年間を使用した。RBF ネットワークのパラメータを以下に示す。

- <RBF ネットワーク>
- 入力変数: 4
- 中間層のユニット数: 6 (クラスタリングにより最適化)
- 学習回数: 5000
- 重み修正幅: 0.1

またシミュレーションのフローを図 3 に示す。まず日射量実測データからクラスタリングを行う。これは過去の似た傾向から未来の予測を行うための特徴量を分類することを目的とする。またクラスタリングの結果から得られた最適なクラスタ数から RBF ネットワークの中間層のユニット数と代表ベクトルが決定される。その後構築された RBF ネットワークに過去 1 年間分の学習データを与えることでパラメータを学習させる。最終的には予測値と実測値を比較し評価を行っていく。

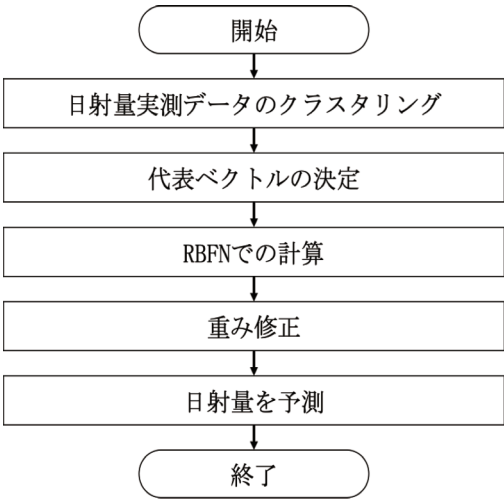


図 3 フローチャート

(2) シミュレーション結果

表 1 にシミュレーション結果の一例を示す。これは日射量実績データのみを用いて、ある 7 日間の予測を行った。7 日間の予測結果から、誤差率が高い日と低い日が混在していることが分かる。誤差率の高い日は、過去の傾向からでは捉えきれない当日の突発的な天候などが影響していると考えられ、雲量データなどの気象データの重要性が示唆された。また、今回の予測モデルでは入力データの特徴によって過去に同じ傾向が多いものは、予測精度が良いが過去に似た傾向が少ないと予測結果に反映されにくく誤差率が大きくなることが確認された。以上より、日射量予測においては、日射量データと雲量データを組み合わせることで予測精度向上を可能とすることから、引く続きシミュレーションを通して検証を行っていく。

表 1 実測値と予測値の比較

	1日目	2日目	3日目	4日目	5日目	6日目	7日目	平均
実測値(kWh)	3.09	3.52	3.96	2.80	3.72	3.44	3.39	
予測値(kWh)	3.20	2.80	3.36	3.00	4.20	3.74	2.79	
誤差率(%)	3.56	20.45	15.15	7.14	12.90	8.72	17.70	12.23

5. まとめ

本稿では、RBF ネットワークに対して過去の日射量実績データと雲量データによる日射量予測を提案した。シミュレーション結果例から限られたデータセットを用いることでも、ある程度の予測精度が確保できることを確認した。今後はさらなる予測精度の向上のための検証を行っていく。また、本稿で用いた予測モデルを他の小規模エリアの日射量予測に適用することで汎用性や予測精度の確認を行っていく。

参考文献

[森 02] 森啓之・青山光・山中俊幸・浦野昌一: DA 前処理付き大域的構造を持つ RBFN の電力系統事故検出への応用, 電学論 B, 122, 12, pp. 1355-1366, 2002.

[気象 18] 気象庁・過去の気象データ(雲量データ: 東京地点) (<https://www.jma.go.jp/jma/index.html>)

[羽柴 18] 羽柴雄太・浦野昌一: ARIMA モデルと RBF ネットワークを用いた電力需要予測の検討, 電力技術/電力系統技術合同研究会, No. PE-18-171 PSE-18-147, 2018.