

追加学習型 Neural Network と山登り法を用いた太陽電池の MPPT 制御

A novel MPPT controller for photovoltaic systems using Incremental Learning Neural Network and P&O method

木幡 泰士 (PY)[†], 山内 康一郎[†]

Yasushi Kohata(PY) and Koichiro Yamauchi

[†] 北海道大学 大学院情報科学研究科

{ya_kohata,yamauchi}@complex.eng.hokudai.ac.jp

Abstract— Maximum Power Point Tracker (MPPT) is often used for solar systems to increase its output power. Perturbation and Observation (P&O) method is widely used for MPPT. But in rapidly changing insolation conditions, the efficiency of P&O decreases. We propose a novel MPPT controller that can adapt to such conditions. The simulation results show that the proposed method yielded highly efficient control.

Keywords— Incremental Learning, Neural Network, Photovoltaic system, MPPT

1 はじめに

太陽電池は日射強度と太陽電池表面温度に依存する定電流源として働き、その時々状況に応じて発電される電力が最大となる最適な動作電圧と動作電流がある。この特異な特性のため、負荷を直接太陽電池に繋ぐと、動作点は負荷に依存してしまい、最適な動作点(最大電力点)で発電できるとは限らない。そのため、発電能力を如何なく発揮するためには、変化する最大電力点を常に追従する最大電力点追従装置(Maximum Power Point Tracker; MPPT [1][2])を利用することが望ましい。

最もよく使われる MPPT 制御法は、出力電力が最大となるように動作電圧を山登り法(Perturbation and Observation method; P&O)を用いて逐次更新するものである。この方法は簡単で比較的性能もよいが、日射強度が急激に変化する場合、最大電力点を追従しきれずロスが大きくなってしまふ。

これを解決するため、ニューラルネットワークを用いてフィードフォワード制御する手法が提案されている[2]。この方法は日射の高速な変化にも対応できるが、使用する太陽電池の出力特性を把握し、学習データセットを得た上で事前に学習を完了させておく必要がある。そのため、専用の MPPT 装置を太陽電池パネルごとに開発することに等しく、開発コストがかかることが予想されると共に、太陽電池の経年劣化に対応できない。

そこで事前に学習データを必要とせず、日射の急激な変化にも対応できる MPPT 制御法を提案する。この手法は山登り法とオンライン学習するニューラルネットワークを組み合わせたものである。本研究ではシミュレーションによる評価を行った。

2 提案手法

ここでは、山登り法を使いつつもニューラルネットワークを学習させ、MPPT のフィードフォワード制御を行う手法を提案する。具体的には、日射の変化が緩やかなときには山登り法を用いながら最大電力点を探索し、最大電力点が見つかった場合にはその都度ニューラルネットワークに学習させる。その一方で、日射の変化が激しい場合にはニューラルネットワークの出力を用いたフィードフォワード制御を行うことで、発電効率の低下を抑える。システムの構造図を図 1 に示す。この

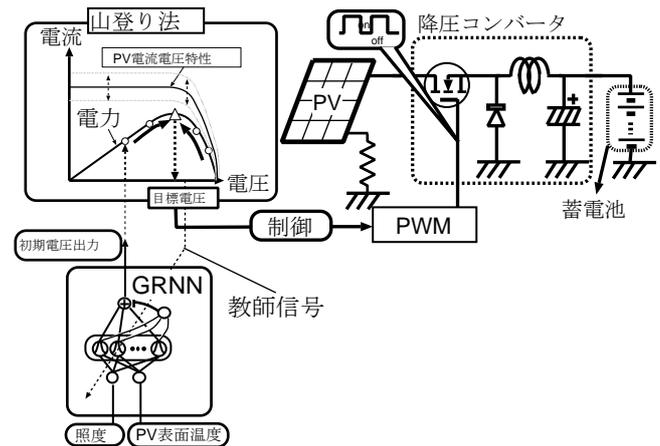


図 1: システム構造図

場合、ニューラルネットワークに提示される学習データは、通常学習機械のオンライン学習時に使用されるような i.i.d データになることは期待できず、日射強度、パネル温度がそれぞれ似通ったデータが連続して得られることが想定される。

そのような状況でもうまく学習できるように、提案手法ではインスタンスベース学習器に近い General Regression Neural Network (GRNN)[3] を用いる。

提案手法で使用する GRNN は基底関数にガウス関数を用い、2 入力 1 出力で、最大電力点の動作電圧に影響する日射強度 S とパネル温度 T を入力し、最大電力点の動作電圧 V_{ref} を出力させる

GRNN の学習は新しいサンプルが与えられると、その学習サンプルと同じ中心位置 c を持ち、標準偏差 σ を持つ基底関数を割り付ける。このユニットのターゲット出力 w は、学習サンプルのターゲット出力と一致さ

せる。さらに本研究では、計算時間やメモリ容量などを考慮し、ユニットを割り付けたときに提示された学習サンプルと似た別の学習サンプルが与えられたとき、 w はその似た学習サンプルに近づくように更新されるものとした。具体的には、学習データ $[\hat{x}, \hat{y}]$ が与えられると、 \hat{x} と GRNN 内で \hat{x} に最も近いユニットの中心位置 $c_{nearest}$ との距離を計測し、その距離が閾値 θ より大きければ新たにユニットを追加する。

$$c_{new} = \hat{x}, \quad w_{new} = \hat{y} \quad (1)$$

一方、閾値 θ より小さい場合は、新たにユニットを追加せずに、入力から最も近いユニットの重み $w_{nearest}$ を変更する。重みの更新は以前の重みと新たに与えられた教師 \hat{y} の平均値とする。

$$w_{nearest} = (w_{nearest} + \hat{y})/2 \quad (2)$$

3 実験

ここでは、実際に太陽電池を使用する状況において、本手法による MPPT が適切に学習可能であることを確かめ、日射強度が急激に変化する場合において本手法が有効に働くことを示す。実験全体を通してノイズや各種機器の応答速度は考えないものとした。

まず実際の状況にある程度近い状況で学習を行う。日射強度やパネル温度が変化していく様子をサインカーブで表す。このとき日射強度のサインカーブとパネル温度のサインカーブの周期を少しずらした上で何周期分か続けることで、日射強度とパネル温度の様々な組み合わせを学習させる。この日射強度とパネル温度の変化方法は、同じような値が学習データとして連続して得られるという点で、実際に学習する状況に近いと言える。

次に学習の終わった GRNN を用い、日射強度の変化が激しい状況での発電効率を測る。同じように日射強度の変化をサインカーブで表現するが、周期をかなり短くしたサインカーブを用いる。このときの日射強度 S の変化と発電された電力、発電電力の理論最適値を図 2 に示す。比較対象として山登り法のみを用いた場合のものも同時に示した。提案手法は理論最適値とほぼかかっているが、山登り法では最大電力点を追従しきれず出力電力が低くなってしまっている。

さらに日射強度のサインカーブの周波数 f を様々な変化させ、それぞれの周波数において最大電力点を完璧に追従できた場合の理論最適値と比較してどの程度の割合で発電できたかを求める。発電効率 r を発電された電力量 W_{out} の理論最適値 W_{best} に対する割合 ($r = W_{out}/W_{best}$) と定義する。横軸に日射変化の周波数 f 、縦軸に効率 r をプロットしたグラフを図 3 に示す。山登り法は変化が緩やかな場合には高い効率を出せているが、変化の激しい状況になるにつれて効率が低下してしまっている。一方、提案手法では高い効率を維持できているのがわかる。

4 まとめ

本稿では、オンライン学習するニューラルネットワークと山登り法とを併用する MPPT コンバータを提案し

た。山登り法は日射変化のゆるやかなときには発電効率が比較的よいが、変化が激しくなるにつれて効率が低下する。一方提案手法は日射変化の緩やかなときには山登り法を行いながら学習できることと、既に学習した領域においては、日射変化の激しい状況であっても GRNN の出力を用いたフィードフォワード制御を行うことで最大電力点を追従できることが確認できた。

しかし、今回のシミュレーションでは観測機器の精度や応答速度、観測誤差など細部までシミュレートしきれしていない。我々は現在、この手法を MPPT チャージコンバータとして実装し、実際に太陽電池に接続して評価することを目指している。

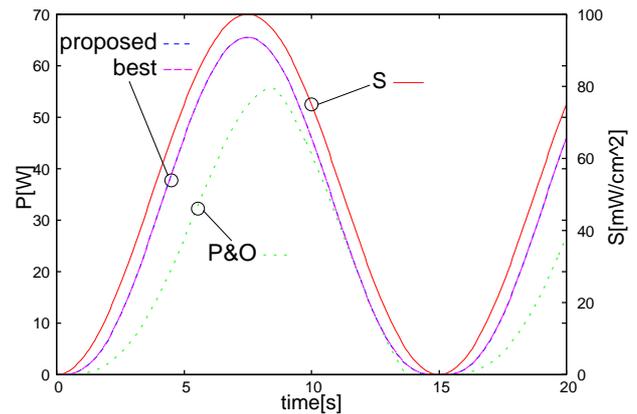


図 2: 発電電力の変化

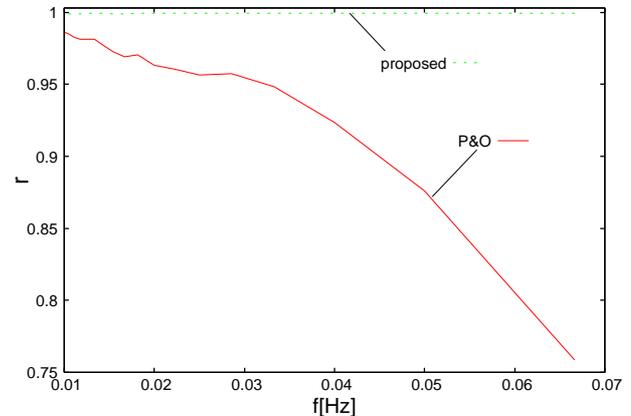


図 3: 日射変化の激しさと発電効率の関係

参考文献

- [1] T. Tafticht, K. Agbossou, M.L. Dombia and A. Cheriti (2008) “ An improved maximum power point tracking method for photovoltaic systems”, *Renewable Energy*, **33**, **7**, 1508–1516.
- [2] R. Akkaya, A.A. Kulaksiz and O. Aydogdu (2007) “ DSP implementation of a PV system with GA-MLP-NN based MPPT controller supplying BLDC motor drive”, *Energy Conversion and Management*, **48**, **1**, 210–218.
- [3] Donald F. Specht (1991) “ A general regression neural network”, *IEEE trans, Neural Networks*, **2**, **6**, 568–576.