

太陽電池の特性を自動学習する高速な最大電力点追従装置の開発と実装

木幡 泰士 †

山内 康一郎 ‡

栗原 正仁 †

† 北海道大学情報科学研究所

‡ 中部大学工学部

1 はじめに

太陽電池は、照度、太陽電池表面温度によって出力電流が変化する電流源として働く。発電効率を上げるためにには、常に最適な動作電圧、すなわち出力電力が最大となる最大電力点 (MPP) で発電することが望ましい。しかし、MPP は照度や温度によって変化してしまう。そこで常に MPP で発電するために、最大電力点追従装置 (Maximum Power Point Tracker ; MPPT[1][2]) が広く用いられている。

しかし、山登り法 (Perturbation and Observation; P&O) に代表される、従来の MPPT 手法の多くは、MPP に到達するまでに時間がかかるため、太陽電池を車両等の移動体に設置した場合等、照度が急激に変化する状況では、MPP を追従しきれずロスが大きくなってしまう。

一方、照度の急激な変化に対応可能な手法として、ニューラルネットワーク (NN) を用いた手法があるが [1]、太陽電池モジュールごとに出力特性が違うため、この手法は NN の学習という事前開発をモジュールごとに行う必要があった。

そこで、モジュールごとの事前開発を必要とせず、照度の急激な変化にも対応可能な MPPT 手法を提案した [4]。今回、この提案手法の計算量を削減する工夫をし、マイクロコンピュータ上に実装して動作検証を行った。

2 提案手法

2.1 概要

ここでは、P&O 法と NN とを組み合わせ、運用中に太陽電池特性を自動学習する手法を提案する (図 1)。すなわち、照度の変化が緩やかなときは P&O 法を用いながら最大電力点を探索し、NN に追記学習させる。しかし照度が急激に変化する場合には NN の出力を制御信号 V_{ref} としてコンバータを制御することによって高速 MPPT を実現する。

提案手法による MPPT の制御は周期的に行われる。ここでは 0.1 秒ごとに制御信号 V_{ref} がコンバータに送信されることとしている。

P&O 法による制御では、1 step ごとに電力を計測しながら、 V_{ref} を ΔV ずつ変化させ、徐々に出力電力の高くなる方向へ動作電圧を変化させて行く。

一方 NN による制御では、そのときに計測された照度 S と温度 T を入力したときの NN の出力値 $y(S, T)$ を V_{ref} とし、コンバーターを制御する。

ここで P&O 制御と NN 制御の大きな違いは、P&O 制御では V_{ref} を 1 step に ΔV しか変化させないため、現在の動作電圧と、最大電力点の動作電圧が離れている場合、最大電力点に到達するまでに、その距離に応じた step 数を要してしまうのに対し、NN 制御では、距離がどれだけ離れていても 1 step で最大電力点付近に到達することが可能である。但し、NN が太陽電池特性を正しく学習していることが前提条件となる。

NN に提示される学習データは、通常、オンライン学習のための必須条件となる i.i.d. データにはならず、照度、温度それぞれが似通ったデータが連続して得られてしまう。このような状況でもうまく追記学習できるように、General Regression Neural Network(GRNN)[3] を用いている。

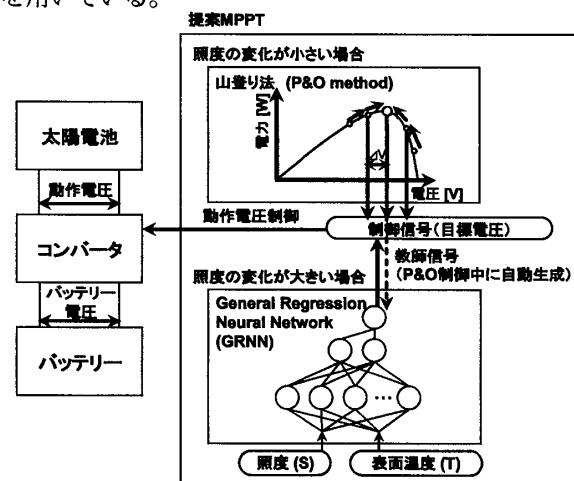


図 1: 提案システム概要図

2.2 実装

先述の提案手法をマイクロコンピュータ上に実装した。ここでは、極力消費電力を抑えるため、DSP の付いていないものを利用する。具体的には H8-3069F を使用し、GRNN の状態を保存しておくために、EEPROM を増設した。H8-3069F の仕様は、CPU25MHz, AD 変換分解能 10bit, DA 変換分解能 8bit である。

Development of High-Speed Maximum Power Point Tracker for Photovoltaic Systems using Machine Learning Techniques
†Yasushi KOHATA ‡Koichiro YAMAUCHI †Masahito Kurihara
†Graduate School of Information Science and Technology, Hokkaido University
‡Chubu University, Department of Information Science

2.3 GRNN

GRNN は連続関数近似器であり、入力層、パターン層、総和層、出力層の 4 層から成る。パターン層のユニット数が J 個である GRNN に、入力 x が与えられたときの出力 $y(x)$ は式(1)のようになる。

$$y(x) = \frac{\sum_{j=1}^J w_j \phi_j(x)}{\sum_{j=1}^J \phi_j(x)}, \quad \phi_j(x) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma^2}\right). \quad (1)$$

ここで、 ϕ_j はパターン層の j 番目のユニットの基底関数、 σ^2 は既定関数の分散、 c_j は基底関数の中心、 w_j は重みである。提案手法では既定関数にガウス関数を用いている。

オリジナルの GRNN の学習は、新たな学習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を持つ新たなユニットを割り付ける。

しかし全ての学習サンプルに対し新たにユニットを割り当てるとなると、メモリ容量の圧迫と、計算量の増大を招く。そこで、学習サンプルが与えられたときに、そのサンプルと GRNN 内の最も近いユニットとの距離が閾値 θ 以下であれば、新たにユニットは追加せず、最近傍ユニットの重みの更新を行うこととした。

計算精度や、メモリ容量を考慮し、GRNN のユニットは最大 100 個程度になるよう、 θ を調整したが、実際に H8-3069F 上で GRNN の出力を計算するときに、ユニットが 100 個もあると計算時間がかかりすぎる。そこで計算量削減のため、GRNN の出力を計算するときに、式(1)の通りに全てのユニットの出力を計算して足し合わせるのではなく、入力から近いユニットの出力だけを足し合わせることとした。

3 実験

筆者らは以前、提案手法の有効性を計算機シミュレーションにより示し、さらに実機を用いた実験（ノート PC による制御）により、現実のノイジーな環境でも期待した動作が行えることを確認した [4]。ここでは、ノート PC に比べ、分解能や処理速度の制限が厳しいマイクロコンピュータ (H8-3069F) 上でも、期待した動作が行えることを確認するために実験を行った。

図 2 は GRNN が何も学習していない状態から提案手法を動作させたとき結果である。尚、短時間の動作では太陽電池表面温度はほぼ一定のため、グラフにはプロットせず、照度 S 、電力 P 、制御信号 V_{ref} のみプロットしてある。前半の 1 分間は、ほぼ P&O のみの動作となっているため、照度の変化よりも少し遅れて電力が上昇している。この期間に、それぞれの照度における最適な制御信号の学習が自動的に行われている。その

後、照度を急激に変化させると、変化直後は GRNN の出力が用いられ、ロスの少ない発電ができる。

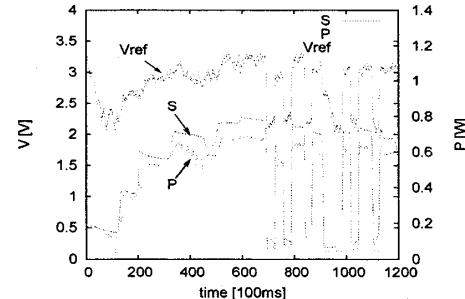


図 2: 提案システムの動作

4 まとめ

モジュールごとの事前開発を必要とせず、徐々に急激な照度変化に対応可能となる MPPT 手法を提案した。提案手法をマイクロコンピュータ H8-3069F 上に実装し、動作検証を行った結果、自動的に太陽電池の MPP を学習し、急激な照度変化に対応可能であることが確認できた。しかし、2.3 節で述べた、GRNN 出力計算時の計算時間削減処理について、さらなる改良と、計算時間と精度についての評価を行う必要がある。特に今回の実験は短時間で行ったため、GRNN ユニット数が少ない状態での動作だったが、今後は様々な照度、温度の下で動作させ、ユニット数が増大した状態での計算速度を計測する必要がある。

参考文献

- [1] R. Akkaya, A.A. Kulaksiz and O. Aydogdu: “DSP implementation of a PV system with GA-MLP-NN based MPPT controller supplying BLDC motor drive”, Energy Conversion and Management, Vol.48, No.1, pp.210 – 218, 2007
- [2] T. Tafticht, K. Agbossou, M.L. Doumbia and A. Cheriti: “An improved maximum power point tracking method for photovoltaic systems”, Renewable Energy, Vol.33, No.7, pp.1508 – 1516, 2008
- [3] Donald F.Specht: “A general regression neural network”, IEEE trans. Neural Networks, Vol.2, No.6, pp.568 – 576, 1991
- [4] Yasushi Kohata, Koichiro Yamauchi, Masahito Kurihara: “Quick Maximum Power Point Tracking of Photovoltaic Using Online Learning Neural Network”, Neural Information Processing: 16th International Conference, ICONIP 2009 Proceedings, PartI, LNCS 5863, pp.606 – 613, 2009.