

# ニューラルネットによる太陽電池特性同定を用いた 最大電力点追従制御の一方式

山田 英二\*・泉 勝弘\*  
辻 峰男\*・松尾 大輔\*\*  
小山 純\*

## A Maximum Power Tracking Control with Identification of Solar Cell Parameters using Neural Network

by

Eiji YAMADA\*, Katsuhiko IZUMI\*, Mineo TSUJI\*  
Daisuke MATSUO\*\*, Jun OYAMA\*

This paper presents a maximum power tracking control method for on-line identification of solar cell parameters using neural network technology. The characteristics of solar cell modules are variables of illumination and temperature of them. Therefore, to obtain characteristic equations of solar cell are required for estimation of optimal operating point. We estimate characteristic equations of solar cell using neural network. And, we can obtain optimal operating point using newton method from characteristic equations of solar cell. The solar power are converted into three-phase AC one by three-phase IGBT voltage-type PWM inverter.

### 1 まえがき

我々の日常生活はすべてエネルギーに依存しており、エネルギーを欠いた生活は考えられない。しかし、我が国のエネルギー使用量は年々増加の一途をたどっており、世界的なエネルギー不足時代の到来が現実問題となってきている。我々が今日使っているエネルギーの大半は、石油や石炭、天然ガスなどの化石燃料を消費することによって得られている。化石燃料に限りのあることを考えればそれに代わるエネルギー源を手に入れることが必要である。

このために、我が国では様々な新エネルギーの研究・開発が進められてきた。最近では、入力となるエネルギーが無尽蔵でただであり、また、クリーンである太陽光発電が将来のエネルギー源として期待されている。

太陽光発電の本格的普及のためには、太陽電池素子の高性能、低価格化や周辺技術の更なる改善が求められている。太陽光発電システムにおいて、太陽電池の出力特性は温度や日射量、風の有無や風速などの自然条件により変動するため、いかに効率良く太陽電池を運用させるかが問題となる。また、系統連系技術ガイドラインが改訂され、逆潮流も可能となった。そこで、系統連系にあたりインバータの直流側を制御し太陽電池を常に最適動作点で動作させる必要がある。

本論文では、太陽電池の本格的普及を見据えて、太陽電池で得られた電力を三相 IGBT 電圧形 PWM インバータにより三相交流に変換する系統連系の太陽光発電システムを構築し、システム全体の効率向上の検証を行った。また効率よく電力を供給するために、太陽光発電システムの直流側より検出した直流電圧、

平成8年4月26日受理

\*電気情報工学科 (Dept. of Electrical Engineering and Computer Science)

\*\*電気情報工学専攻 (Graduate Student, Dept. of Electrical Engineering and Computer Science)

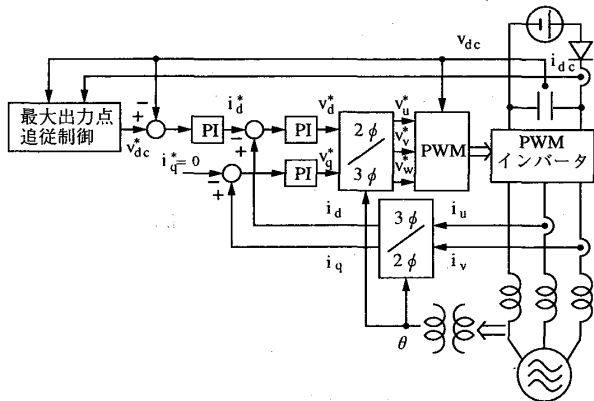


Fig. 1 Photovoltaic system.




Fig. 2 Estimation of optimal operating point.

直流電流を入力とするニューラルネットワークを用いた太陽電池出力電力を最大にする制御方法を新しく提案した。

## 2 最大電力点追従制御

### 2.1 制御システム

図1に太陽電池の最大電力制御系の構成を示す。これは、太陽電池による系統への電力の回生を目的としているため電流の向きが逆になるが、インバータを制御対象にした電流制御系と同じ構成である。この制御系には、電圧・電流等の検出部およびPWM出力部、最大電力制御には最大電力検出部および電流制御部がある。最大出力点制御部は、図2に示すように、ニューラルネットワークで推定した太陽電池特性式から、極値解法のニュートン法で、最大電力点の動作電圧を求め、指令電圧  $v_{dc}^*$  とする。電流制御部のマイナー・ループはd軸とq軸とに分けて構成され、力率1とするためにq軸指令電流を  $i_q^* = 0$  とおく。さらに、出力電圧を制御系内部にフィードバックし、指令電圧  $v_{dc}^*$  とのPI制御をとり、その操作量をd軸指令電流  $i_d^*$  とする。これにより、出力電圧が最大電力検出部で求めた指令電圧に追従し、最大電力点で動作できる。

図2に、最大出力点追従制御部の構成を示す。太陽電池の直流側から検出してきた直流電流・直流電圧より、ニューラルネットワークを使って太陽電池特性式を推定し、ニュートン法を使って最適動作点を求め、それを指令電圧とする。




Fig. 3 P-V curve of solar cell.

### 2.2 太陽電池出力特性

太陽電池の出力電力の実測値（照度11000lx, 温度10.0℃, モジュール8枚）を図3に示す。

太陽電池モジュールは日射量, 温度によって特性が異なっている。それは、太陽電池自身に固有の特性を表す式が存在しており、その要素として日射量, 温度が大きく影響しているからである。逆に言えば、この式を解析的に導くことが出来れば、その式から最適な電力が得られる点を求めることは容易である。

この特性式は制御系の構成によって変わってくるが、もっとも一般的なのは<sup>3)</sup>,

$$I = I_{sh} - I_0 \left[ \exp\left(\frac{qV}{AkTc}\right) - 1 \right] \quad (1)$$

$$I_{sh} = I_{sh} + K_i(T_c - 301) \phi / 100 \quad (2)$$

$$I_0 = I_{or} \left(\frac{T_c}{T_r}\right)^3 \exp\left[\frac{qE_{g0}}{Bk} \left(\frac{1}{T_r} - \frac{1}{T_c}\right)\right] \quad (3)$$

である。この式の係数を求めるには、日射量と温度の値が必要になってくる。これらの値をセンサを用いて検出して制御に使う場合と、何らかの推定法でその値をソフト的に推定して使う場合とがある。<sup>1) 2)</sup>

どちらの方式がよいとはいえないが、リアルタイムな制御を行う場合には後者が適している。本論文では後者を利用している。

### 2.3 ニューラルネットワーク

(1)~(3)式をもとにネットワークを組み、そのネットワークの構成を図4に示す。

この構成図から、今回のニューラルネットワークを組むにあたって導出された学習則の演算式は以下に示す通りである。

$$T_c = T_r * W_h \quad (4)$$

$$V_j = V_{dc} + I_{dc} * W_R \quad (5)$$

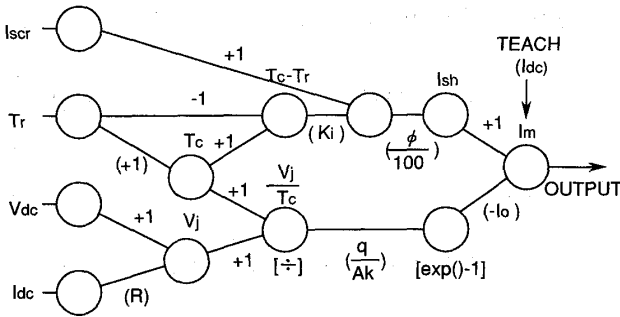


Fig. 4 Configuration of neural network.

$$\begin{aligned}
 T_{cr} &= T_c - T_r & (6) \\
 V_t &= V_j / T_c & (7) \\
 I_{cr} &= I_{scr} + T_{cr} * W_K & (8) \\
 I_{sh} &= I_{cr} * W_\phi & (9) \\
 A &= V_t * W_{QAK} & (10) \\
 I_m &= I_{sh} - W_{IO} [A - 1] & (11)
 \end{aligned}$$

各式に用いられているニューロンや荷重の初期値は、その学習の目的によって大きく異なってくる。例えば今回のように太陽電池を使ったシステムで初期値を設定するにしても、モジュールを4枚使う場合と8枚使う場合とでは異なってくるし、またシステムの構成、あるいは自然条件などによっても微妙に変わってくる。そういった理由から実験する時の条件に最も見合った値を設定しておくことが必要である。

また、ニューラルネットワークにおいて、最も重要な意味を持つのがネットワーク間の荷重の修正である。これは、出力層で生じた誤差を出力層側から入力層側へと逆方向に伝搬し、ネットワーク全体の荷重を修正するという、バックプロパゲーション則に基づい

Table 1 Parameters of characteristic equation.

$\phi$	日射強度 [mW/cm <sup>2</sup> ]
$q$	電荷量 (=1.602×10 <sup>-19</sup> c)
$k$	ボルツマン定数 (=1.380×10 <sup>-23</sup> J/K)
$T_c$	セル温度 [K]
$T_r$	参照温度 (=301.18 [K])
$I_{sh}$	短絡電流 [A]
$I_o$	飽和電流 [A]
$I_{or}$	温度 $T_r$ のときの飽和電流 [A]
$I_{scr}$	温度28℃, 日射強度100mW/cm <sup>2</sup> 時の短絡電流 [A]
$E_{go}$	シリコンのバンドギャップ (=1.11eV)
A, B, $K_i$	太陽電池固有の定数

ている。この誤差伝搬のやり方によって、修正される値が大きく変わってくる。これには様々な伝搬のルールがあるが、非線形な誤差修正値を得るために、シグモイド関数と指数関数と線形関数を組み合わせて用いる。荷重の誤差修正項の値は、この二つの関数に各ニューロンの値を代入したもから導く。その修正項の式と修正する際の荷重の計算式を以下に示す。(12)~(16)式が修正項で、(17)~(22)式が荷重の式である。

$$\begin{aligned}
 \sigma_{IM} &= (TEACH - H(I_M)) * H'(I_M) & (12) \\
 \sigma_A &= \sigma_{IM} * W_{IO} * F'(A) & (13) \\
 \sigma_{Icr} &= \sigma_{IM} * W_\phi * S'(I_{cr}) & (14) \\
 \sigma_{vt} &= \sigma_A * W_A * S'(V_t) & (15) \\
 \sigma_{Icr} &= \sigma_{Icr} * W_K * S'(T_{cr}) & (16) \\
 W_{IO} &= W_{IO} + \sigma_{IM} * F(A) \alpha(I_O) & (17) \\
 W_{QAK} &= W_{QAK} + \sigma_A * S(V_t) \alpha(QAK) & (18) \\
 W_\phi &= W_{phi} + \sigma_{IM} * S(I_{cr}) \alpha(\phi) & (19) \\
 W_K &= W_K + \sigma_{Icr} * S(T_{cr}) \alpha(K) & (20) \\
 W_R &= W_R + \sigma_{vt} * S(I_{dc}) \alpha(R) & (21) \\
 W_H &= W_H + \sigma_{Tcr} * S(T_r) \alpha(H) & (22)
 \end{aligned}$$

ここで、 $F(\cdot)$ :Exponential 関数  $H(\cdot)$ :sigmoid 関数  $S(\cdot)$ :線形関数

今回は、ネットワーク内部のすべての荷重を修正するわけではなく、修正が不要と思われる部分は荷重を固定し、荷重の修正量の大小は、各ニューロンごとに与えた、修正比率を定める値 $\alpha$ を用いて調節した。

これらの値も前述同様、使用される条件によって設定が大きく変わってくるのは言うまでもない。

このネットワークにおいて検出した直流電流、直流電圧の値をネットワークの入力層に入れる。教師信号は直流電流値とする。このネットワークを通過した出力信号の値と教師信号との誤差をネットワーク内のすべての重みに誤差伝搬させ出力値と教師信号との差が、ある一定精度に収束するまで繰り返す。収束したら、その時点でのネットワークのニューロンの値と重みの値から、その入力値を入力した時点での太陽電池特性式の(1)式そのものと、各パラメータの値が得られる。その得られた特性式を用いて、数値計算法により式の極値を求め、その極値の値を最大電力点電圧とする。




Fig. 5 Three phase voltage type inverter.

3 シミュレーション

図5に三相電圧形 PWM インバータの構成図を示す。電源電圧を  $e_u, e_v, e_w$ 、インバータ側の電圧を  $v_u, v_v, v_w$ 、入力電流を  $i_u, i_v, i_w$  とすると逆潮流であるから、次式が成り立つ。

$$\begin{bmatrix} v_u \\ v_v \\ v_w \end{bmatrix} = (R+Lp) \begin{bmatrix} i_u \\ i_v \\ i_w \end{bmatrix} + \begin{bmatrix} e_u \\ e_v \\ e_w \end{bmatrix} \quad (23)$$

ただし、

$p$ : 微分演算子,  $L$ : 三相電源とインバータ間に挿入されたインダクタンス,  $R$ : その巻線抵抗

ここで、電源は線間電圧実効値を  $E$ 、電源角周波数を  $\omega$  の平衡三相電圧であるとする、電源電圧は次式で表される。

$$\begin{bmatrix} e_u \\ e_v \\ e_w \end{bmatrix} = \sqrt{\frac{2}{3}} E \begin{bmatrix} \sin\theta \\ \sin(\theta - \frac{2}{3}\pi) \\ \sin(\theta - \frac{4}{3}\pi) \end{bmatrix} \quad (24)$$

ここで、 $\theta = \omega t + \theta_0$

図6に示すような、 $\theta$  で回転する d-q 座標系を考える。⑬, ⑭式を d-q 軸量に変換すると、<sup>6)</sup>

$$v = Ri + Lp i + \omega L j i + e \quad (25)$$

ここで、 $e = [E, 0]^T, v = [v_d, v_q]^T, i = [i_d, i_q]^T$  となり、電源電圧は、d 軸方向で大きさが電源線間電圧の実効値  $E$  に等しいベクトルとなる。

⑮式より次式が得られる。




Fig. 6 d-q axis.

$$pi = -\frac{R}{L}i - \omega ji + \frac{1}{L}(v - e) \quad (26)$$

インバータでの損失が無いとき、インバータ瞬時出力電力  $p_c$  は

$$p_c = v_d i_d + v_q i_q \quad (27)$$

であり、出力直流電圧を  $v_{dc}$ 、直流電流を  $i_{dc}$  とすれば、

$$p_c = v_{dc}(i_{dc} - Cp v_{dc}) \quad (28)$$

と表せるので、出力直流電圧は、次式により表現できる。

$$pv_{dc} = \frac{i_{dc}}{C} - \frac{v_d i_d + v_q i_q}{C v_{dc}} \quad (29)$$

実際にニューラルネットを使ってシステムを制御する際、いろいろなことが問題となってくる。それは、学習は一制御周期内に確実に終了できるのか、他の処理に影響を及ぼすようなことはないのか、仮に学習が終了したとしても、得られた値が望ましい値なのかどうかなどである。これらの事を明確にするため制御システムのシミュレーションを行った。

図7、図8にシミュレーションのフローチャートを示す。このシミュレーションにおいて、制御系のモデルを示す微分方程式を4次のルンゲクッタを用いて解き、今回の検出値  $V_{dc}, I_d, I_q$  を得る。それらの値と指令値を用いた PI 制御により得られた、 $V_d, V_q$  を次回

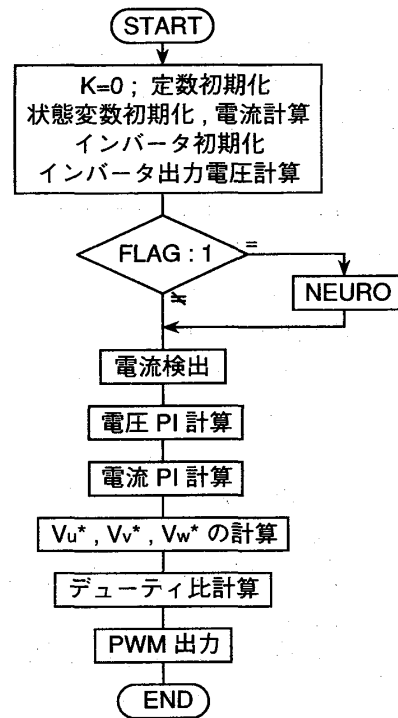


Fig. 7 Flowchart of simulation.

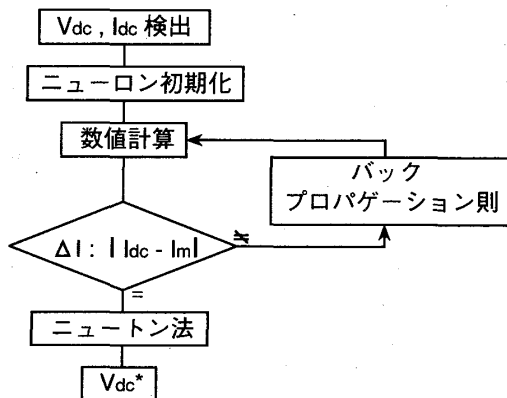


Fig. 8 Flowchart of estimation of optimal operating point.

のモデル解析に使っている。

ある一定の制御回数を経た後、ニューラルネットを用いた最大出力電圧追従制御を含めた処理の流れとなる。ニューラルネットの学習則と誤差逆伝搬則の演算は一制御周期内で1回のみ行い、学習則の演算後に収束の状況を確認する。収束が完了すれば、そのニューラルネットに検出値を入力した時点での照度における太陽電池の特性曲線が求められることになる。この曲線から、ニュートン法を用いてその特性式の極値（現在の照度における最大出力点電圧）を求める。そして、その値を次の制御周期の指令電圧  $V_{dc}^*$  としている。

また、照度が変わってからニューラルネットが最大電力点電圧に追従できるかどうかを確認するため、ある制御回数を経た時点で照度を変化させている。ここでは、照度が変わったものとするために直流電流  $I_{dc}$  の値のある時点で異なる値にしている。これは、同じ指令電圧で電流値が変化しているのだからすなはち照度が変わったことと同じであることを利用して

#### 4 結果

今回、行ったシミュレーション結果を図9に示す。図9(a)、図9(b)は照度下降時の、図9(c)、図9(d)は照度上昇時のシミュレーション波形である。

図9(b)、図9(d)は指令電圧  $v_{dc}^*$  に±10%リミッタをつけている。それは、急激な電圧指令値の変化よりシステムを保護するためである。

上から順に、推定照度  $\phi$ 、指令電圧  $v_{dc}^*$ 、直流電圧  $v_{dc}$ 、直流電流  $i_{dc}$ 、電力  $P$  の波形である。ここでは、ニューラルネットの学習間隔を制御周期と同じ260.5  $\mu\text{sec}$  としている。130Vの指令電圧から制御を開始し、照度が変わることにより、直流電流  $i_{dc}$  が変化するので、その変化をニューラルネットワークが認識し、

学習して最大出力点電圧や照度を推定している。

また、照度下降時と照度上昇時でステップの幅が違うのは、ニューラルネットワークの非線形性のためであると思われる。

#### 5 あとがき

本論文では、ニューラルネットワークを用いた太陽電池最大出力点電圧追従制御法により、太陽電池出力を効率よく三相交流に変換する、系統連系用の三相IGBT電圧形PWMインバータ太陽光発電システムを構築した。

ニューラルネットワークを構成するにあたって、太陽電池の特性式との対応が明瞭であるようにし、また、ニューラルネットの特性近似の問題点である照度の推定が不明確である点を改善した。


また、太陽電池の直流電圧、直流電流からニューラルネットワークを用いて、太陽電池の特性式を推定し、最大電力点電圧を数値計算法により求めた。

それにより、別にモニタ用の太陽電池を必要とせず<sup>4) 5)</sup>、従来に比べて有用かつ経済的な太陽光発電システムの構築が可能になった。


今後は、ニューラルネットの特性式近似の精度を上げ、安定した最大電力を供給できるようにしたい。

#### 参考文献


- 1) 石井・関口・谷：「太陽光発電・燃料電池ハイブリッドシステムの最適設計」, 平成6年電気学会全国大会, No.1673
- 2) 西川：「スタンドオフ方式アレイにおける太陽電池温度特性(その1)」, 平成6年電気学会全国大会, No.1680
- 3) BIMAL K. BOSE：「Microcomputer Control of a Residential Photovoltaic Power Conditioning System」, IEEE TRANSACTIONS ON INDUSTRY APPLICATIONS, Vol. IA-21, No. 5, SEPTEMBER/OCTOBER 1985
- 4) 上妻・今久保・松山：「ニューラルネットによる電力用太陽電池モジュールの最適動作点の実時間推定」, 電気学会論文誌 B, vol. 114, No. 9, pp. 881-887 (平6)
- 5) 上妻・今久保・松山・北林：「ニューラルネットを用いた太陽光発電システムの実時間最大電力追従制御に関する研究」, 平成7年電気学会全国大会, No.1793
- 6) 辻・山田・小山・泉：「三相誘導機の2軸理論の応用」, 長崎大学工学部研究報告, 14, 22 (昭59-1)




(a) Step down.



(c) Step up.



(b) Step down with limiter.



(d) Step up with limiter.

Fig. 9 Simulation results.