ニューラルネットワークを用いた PWM インバータ のデジタル電流制御

正員 伊藤 良久 (ソニー)

正員 古橋 武 (名古屋大)

正員 大熊 繁 (名古屋大)

正員 内川 嘉樹 (名古屋大)

A Digital Current Controller for a PWM Inverter using a Neural Network

Yoshihisa Ito, Member (SONY), Takeshi Furuhashi, Member, Shigeru Okuma, Member,
Yoshiki Uchikawa, Member (Nagoya University)

Performance of a digital current controller for a PWM inverter is degraded by changes of load impedances and delay necessary for calculation of the controller.

This paper presents a digital current controller for a PWM inverter using a neural network. The current controller automatically tunes its gains to the optimal ones for varying load impedances and compensates the calculation delay. Stability condition for the learning rate of the neural network is analyzed. The feasibility of the new controller is verified by simulations and experiments. Stable region of the current controller with deviations of the load impedances is obtained by simulations.

キーワード：ニューラルネットワーク，PWM インバータ，デジタル電流制御，学習，安定性

1. はじめに

近年の目覚ましい電力用半導体素子およびマイクロプロセッサの発展により，デジタル制御による PWM インバータが普及し始めている。PWM インバータの出力電流追従性能は，負荷インピーダンスの変動により低下し，デジタル制御器による演算遅れにより更に低下する。

PWM インバータの電流追従性能を向上させる手法として，繰返し制御⁽¹⁾および学習制御⁽²⁾による方法が提案されているが，これらの制御法は，電流指令値に変更があるたびに再学習を行い，収束に数サイクルを要している。また，電流指令値の 1 サンプル先を予測する手法⁽³⁾は制御系の演算遅れを有効に補償できるが，負荷インピーダンスの変動を考慮していない。

さて，近年ニューラルネットワーク⁽⁴⁾が注目を集めている。ニューラルネットワークは，学習能力，非線形変換能力，並列処理などの特徴をもち，画像認

識，音声認識，ロボット制御などへの応用がさかんに研究されている。本論文では，ニューラルネットワークを PWM インバータの電流制御系に適用することを検討し，負荷インピーダンス変動および電流制御系の演算遅れによる電流追従性能の低下を改善できることを示す。併せて，ニューラルネットワークの学習法を示し，学習の安定を保證する学習率の範囲を明らかにする。本ニューラルネットワークは，学習の収束に 10 サイクル程度を要するが，学習が十分に進んだ後には，学習を止め電流指令値が変化しても高調波の次数が変わらない限り，1 サイクル後に出力電流の誤差は収束する。最後に，本制御系の妥当性をシミュレーションおよび実験により検証し，負荷インピーダンス変動の許容範囲をシミュレーションにより明らかにする。

電力変換器にニューラルネットワークを適用した例は本論文が初めてであり，本論文が今後の電力変換器へのニューラルネットワーク応用の一つの指針になり

得ると考える。特に、アクティブフィルタに代表されるような、基本波の周波数および高調波成分の次数にあまり変動がないような用途には、ニューラルネットワークを用いた本論文のシステムが有効であると考える。

2. 電流制御系

図1は、三相PWMインバータおよび本論文で提案する電流制御系の構成を示す。PWMインバータは電圧形とし、負荷は簡単のためR-L負荷とする。電流制御系は、ニューラルネットワークを用いてフィードフォワードループを構成し、ニューラルネットワークの学習によりフィードフォワードゲインを決定するシステムである。電流制御系は、U相、V相の電流指令値 i_u^* 、 i_v^* のサンプル値 $i_u^*(n)$ 、 $i_v^*(n)$ をニューラルネットワークの入力とし、ニューラルネットワークの出力として、U相、V相の電圧指令値 $v_u^*(n)$ 、 $v_v^*(n)$ を得、これらを三角波キャリア信号と比較してインバータ各相のスイッチング信号を得ている。W相の電圧指令値 $v_w^*(n)$ は、 $v_w^*(n) = -v_u^*(n) - v_v^*(n)$ により得る。 T_s はサンプリング周期である。

図1 主回路構成
Fig. 1. Main circuit configuration.

図2 ニューラルネットワーク
Fig. 2. Neural network.

図2はニューラルネットワークの一相分の構成を示す。本ネットは電流指令値 i_p^* ($p=u, v$) を電圧指令値 v_p^* ($p=u, v$) に変換する。 Z^{-1} は遅延素子で、信号を1サンプル分遅らせて伝搬する。入力層には N 個のユニット $U_{i1} \sim U_{iN}$ があり、電流指令値の基本波の1周期のサンプリング回数と一致するように N を設定している。ネットの構成法には、遅延素子を用いず、ネットの入力層の各ユニットに前処理用としてそれぞれカットオフ周波数の異なる一次進みフィルタを設ける方法がある⁽⁹⁾。しかし、フィルタにより各高調波を弁別するには限度があり、電流指令値が多くの高調波を含む場合には学習の収束性が極度に劣化する。そこで、ネットの構成を図2のようにし、電流指令値の基本波1周期分のデータをネットの入力とすることにより、電流指令値の各高調波成分の情報をネットに入取れることにした。

入力層の各ユニット $U_{i1} \sim U_{iN}$ の入力 $i_p^*(n)$ 、 $\dots$ 、 $i_p^*(n-N+1)$ であり、これはそのまま各ユニットの出力となる。 $h_{p1(n)} \sim h_{pN(n)}$ は入力層のユニット $U_{i1} \sim U_{iN}$ と出力層のユニット U_0 との間の結合係数であり学習アルゴリズムを用いて1サンプリングごとに更新する。ネットの出力 $v_p^*(n)$ は

$$v_p^*(n) = \sum_{i=1}^N \{ i_p^*(n-i+1) \times h_{pi(n)} \} \\ = i_p^*(n)^T \cdot h_{p(n)} \quad \dots \dots \dots (1)$$

ただし、

$$i_p^*(n) = (i_p^*(n), \dots, i_p^*(n-N+1))^T \\ h_{p(n)} = (h_{p1(n)}, \dots, h_{pN(n)})^T$$

と得られる。 $i_p^*(n)$ を電流指令値ベクトル、 $h_{p(n)}$ を結合係数ベクトルと呼ぶ。

本ネットは図2の構成としたことにより、適応フィルタの構成と基本的に同じになっているが、適応フィルタが入力電流信号に含まれる電流成分を取出すのに対し、本ネットは電流指令値から電圧指令値を作り出していること、および本ネットの構成が2層パーセプトロンの1変形とみなせることから本論文では図2のシステムをニューラルネットワークと呼ぶ。

図3は図1のシステムの一相分の近似等価回路であ

図3 一相分の等価回路
Fig. 3. Equivalent circuit of one-phase.

る。制御系の演算遅れを遅延要素 Z^{-1} で表し、三角波比較および PWM インバータの部分の零次ホールドおよび固定ゲイン K で近似している。ネットの出力 $v_p^*(n)$ とインバータの出力電流 $i_{p(n)}$ の間には次の関係がある。なお、以後 $p=u, v$ とする。

$$i_{p(n)} = \varepsilon i_{p(n-1)} + \frac{K}{R}(1-\varepsilon)v_p^*(n-2) \quad (2)$$

ただし、

$$\varepsilon = \exp\{(-R/L)T_s\}$$

ニューラルネットワークの学習に用いる誤差信号 $e_{p(n)}$ を

$$e_{p(n-2)} \equiv V_{p0}^*(n-2) - V_p^*(n-2) \quad (3)$$

と定義する。ただし、 V_{p0}^* はネットの望ましい出力である。負荷インピーダンスなどの推定値が正しいとすると、(3)式は(2)式より

$$\begin{aligned} e_{p(n-2)} &= \frac{R/K}{1-\varepsilon} \{ (i_p^*(n) - i_{p(n)}) \\ &\quad - \varepsilon(i_p^*(n-1) - i_{p(n-1)}) \} \\ &\equiv \alpha(i_p^*(n) - i_{p(n)}) + \beta(i_p^*(n-1) - i_{p(n-1)}) \end{aligned} \quad (4)$$

となる。ネットの結合係数ベクトル $h_{p(n)}$ はニューラルネットワークの学習アルゴリズムの基となったデルタルール⁽⁴⁾により更新する。

$$h_{p(n)} = h_{p(n-2)} + \mu e_{p(n-2)} i_p^*(n-2) \quad (5)$$

ここで、 μ は学習率と呼ばれる。

3. 学習の安定性

誤差信号 $e_{p(n)}$ の計算に用いる R, L が負荷のインピーダンスの R, L と一致しているとして、ニューラルネットワークの学習が安定であるための学習率 μ の範囲を求める。

システムのパラメータに変動がないとしたので、

(4)式は(1)式を用いて

$$\begin{aligned} e_{p(n-2)} &= \alpha i_p^*(n) + \beta i_p^*(n-1) - (\alpha i_{p(n)} + \beta i_{p(n-1)}) \\ &= i_p^*(n-2)^T h_{p0} - i_p^*(n-2)^T h_{p(n-2)} \end{aligned} \quad (6)$$

と表される。ここで、 h_{p0} は誤差信号 e_p を常に零とするネットの結合係数ベクトルである。(6)式を(5)式に代入すると

$$\begin{aligned} h_{p(n)} &= h_{p(n-2)} + \mu i_p^*(n-2)^T \\ &\quad \times (h_{p0} - h_{p(n-2)}) i_p^*(n-2) \\ &= h_{p(n-2)} + \mu i_p^*(n-2) i_p^*(n-2)^T \\ &\quad \times (h_{p0} - h_{p(n-2)}) \end{aligned} \quad (7)$$

となる。結合係数誤差ベクトル $C_{p(n)}$ を

$$C_{p(n)} \equiv h_{p(n)} - h_{p0} \quad (8)$$

と定義すると、(7)式は

$$\begin{aligned} C_{p(n)} &= C_{p(n-2)} - \mu i_p^*(n-2) i_p^*(n-2)^T C_{p(n-2)} \\ &= (I - \mu i_p^*(n-2) i_p^*(n-2)^T) C_{p(n-2)} \\ &= S_{p(n-2)} C_{p(n-2)} \end{aligned} \quad (9)$$

となる。 $S_{p(n-2)}$ を誤差遷移行列と呼ぶ。

誤差遷移行列 $S_{p(n)}$ の固有値 $\lambda_1, \dots, \lambda_N$ および固有ベクトル $x_1, \dots, x_N$ は次式で与えられる。

$$\left. \begin{aligned} \lambda_1 &= 1 - \mu i_p^*(n) i_p^*(n), \quad x_1 \parallel i_p^*(n) \\ \lambda_2 &= \lambda_3 = \dots = \lambda_N = 1, \quad x_2, \dots, x_N \perp i_p^*(n) \end{aligned} \right\} \quad (10)$$

(5)式より、結合係数ベクトル h_p はベクトル i_p^* に平行な方向に限定されて更新されていくので、結合係数誤差ベクトル C_p の収束は固有値 λ_1 により決定される。また、固有値 λ_1 の式に含まれる $i_p^*(n) i_p^*(n)$ は、電流指令値ベクトル $i_p^*(n)$ が電流指令値の1周期分のデータからなることにより、ほぼ(1周期間のサンプル回数) $\times$ (電流指令値の実効値の2乗) $(= NI_e^{*2})$ に等しい定数となる。従って、学習の安定条件は、固有値 λ_1 の大きさが1未満になることから

$$|1 - \mu NI_e^{*2}| < 1 \quad (11)$$

と得られる。(11)式より学習率 μ の範囲は

$$0 < \mu < \frac{2}{NI_e^{*2}} \quad (12)$$

となる。結合係数誤差ベクトルの収束は、固有値 λ_1 の大きさが0のとき、すなわち $\mu = 1/(NI_e^{*2})$ のときに最も速くなる。

PWM インバータが設計された段階で、その出力電流の定格値は決定されるので、(12)式よりシステムが安定であるための学習率 μ の最適値および上限を明確にできる。

4. シミュレーションと実験

実験システムの構成を図4に示す。パーソナルコンピュータは NEC 社の PC 9801 (クロック 12 MHz)、ディジタルシグナルプロセッサ (DSP) ボードはマイテック社の MSP-77230 を用いた。PWM インバータは、200 V、2.5 kVA 定格の市販の三相トランジスタインバータを用いた。パーソナルコンピュータは、CT によって検出したインバータの出力電流値 $i_{p(n)}$ を DSP に転送し、DSP の演算終了後に DSP からの出力電圧指令値 $v_p^*(n)$ を読出して三角波の PWM キャリヤ信号との比較を行い、得られたスイッチング信号をインバータのドライブ回路に出力する。DSP は (1)、(5)式で表されるニューラルネットワークの演算、および(4)式で表される誤差信号の演算を行う。

図 4 実験装置構成
Fig. 4. Configuration of experimental system.

表 1 シミュレーションおよび実験条件
Table 1. Simulation and experimental condition.

スイッチング周波数	f_{sw}	1.5 kHz
サンプリング周波数	f_{sAMP}	1.5 kHz
負荷インピーダンス	R	14.0 Ω
	L	32.0 mH
DC 電 圧	V_{DC}	270 V
入力層のユニット数	N	30

表 1 はシミュレーションおよび実験の条件を示す。PWM インバータのスイッチング周波数は 1.5 kHz とした。また、サンプリング周期 T_s は三角波キャリア信号の周期と同じとし、電流指令値の基本波の周波数を 50 Hz とした。これより電流指令値 1 周期中に 30 回のサンプリングをすることになるので、入力層のユニット数 N は 30 となった。電流指令値は、基本波および五次、七次の高調波を含んだもので三相对称とし、 U 相の指令値を次式で与える。

$$i_u^* = 3.5 \times \{ \sin \omega t + (1/5) \sin 5\omega t + (1/7) \sin 7\omega t \} \quad (A) \quad (13)$$

また、学習率 μ は最適値である $1/(Nl_e^2)$ としている。なお、シミュレーションでは、三角波比較をキャリア 1 周期中に 320 回行っているが、実験ではパーソナルコンピュータ内で 32 回行っている。

図 5、図 6 は、それぞれ 1 周期を 1 回として 30 回学習を繰返したときのシミュレーションおよび実験の結果を示す。各 (a) 図は 1 回目、15 回目の出力電流およびその指令値のサンプル点のデータを直線で補間して示す。また、各 (b) 図は、

$$E = \sum_{n=1}^N \{ i_u^{*(n)} - i_{u(n)} \}^2 \quad (14)$$

で計算される各周期ごとの誤差 E を示す。(a)、(b) 図とも、実験結果はシミュレーション結果とほぼ一致していることがわかる。第 1 回目の波形において

図 5 シミュレーション結果
Fig. 5. Simulation results.

図 6 実験結果
Fig. 6. Experimental results.

両者に少し違いが見られるが、これはシミュレーションの負荷が理想的な $R-L$ 負荷であるのに対して、実験で用いたリアクトルの周波数特性が理想的でないことが主な原因と考えられる。また、実験結果では誤差 E が零に収束していないが、これは、実験では三角波比較の回数がキャリア 1 周期内で 32 回と少ないことによる。

次に、電流指令値が変化した場合の、出力電流の追従性能に関する実験結果を示す。ニューラルネットワークの学習が進み、誤差が十分に収束した後に、電流指令値の高調波の振幅および位相を次のように変化させた。

$$i_u^* = 3.5 \times \{ \sin \omega t + (1/3) \sin(5\omega t + \pi/5) + (1/9) \sin(7\omega t - \pi/9) \} \quad (A) \quad \dots\dots\dots (15)$$

また、電流指令値を変化させるのと同時にニューラル

ネットワークの学習(結合係数ベクトルの更新)を停止した。図 7、図 8 は、それぞれ電流指令値が変化した直後の 1 周期目と 2 周期目の、シミュレーションおよび実験の結果を示す。シミュレーション、実験とも変化した直後の 1 周期目前半は変化前の波形の影響が残っているが、1 周期目後半からは新しい指令値に追従し、2 周期目にはほぼ一致している。このことにより、ニューラルネットワークの学習が十分に行われた後では、出力電流指令値が変化しても、含まれる高調波成分が変化しなければ再学習を要しないことがわかる。

更に、誤差が収束したあとのシミュレーション結果と実際の出力波形をそれぞれ図 9、図 10 に示す。図 9 は電流指令変更前、図 10 は電流指令変更後の出力電流波形である。これらの結果においてもシミュレーションと実験は、スイッチングリブルなど、波形の細部の特徴まで一致している。図 11 は、図 9(a) の波形

図 7 シミュレーション結果(学習停止)
Fig. 7. Simulation results(learning is halted).

図 8 実験結果(学習停止)
Fig. 8. Experimental results(learning is halted).

図 9 出力波形
Fig. 9. Output current.

図 10 出力波形(学習停止)
Fig. 10. Output current (learning is halted).

をFFTにより各調波に分解した結果を示す。各調波の次数を n 、電流指令値および出力電流の振幅をそれぞれ I_n^* 、 I_n として、誤差 $IE(n)$ を、

$$IE(n) = \frac{|I_n^* - I_n|}{I_n^*} \times 100 \quad \dots\dots\dots (16)$$

と定義する。比較のためにPD制御による結果を併せて示す。PD制御では電流指令値と出力電流の誤差を比例・微分ゲインにより増幅し、電圧指令値としている。シミュレーション条件は表1と同じであり、演算遅れはなしとした。PD制御ではサンプリング周波数が1.5 kHzと低いために高調波成分の誤差が非常に大きくなっている。

図 11 出力電流の誤差
Fig. 11. Errors of output current.

図 12 誤差のシミュレーション結果
(学習率変更)

Fig. 12. Simulation results of error (learning rate is changed).

次に、学習率 μ が最適値 $\{2/(NI_e^{*2})\} \times 0.5$ からずれたときの誤差の収束状況について、シミュレーションおよび実験で調べた。図12がシミュレーション結果、図13が実験結果であり、各(a)、(b)図は学習率 μ をそれぞれ最適値の0.2倍、1.8倍にしたときの誤差 E の収束の様子である。学習率が最適値より小さい場合は、シミュレーション結果と実験結果はよく一致している。学習率 μ が最適値より大きい場合には実験結果のほうが振動的な傾向が見られた。これは前述のように、実験ではリアクトルの周波数特性が理想的ではなく、高周波領域でインダクタンスが低下し、等価的に学習ゲインが大きくなって電流制御系がより振動的になったためと思われる。

更に、パラメータ変動が電流制御系の安定性に与える影響をシミュレーションにより調べた。学習率 $\mu = \{2/(NI_e^{*2})\} \times 0.5$ とし、誤差信号 e_p の演算 [(4)式] に用いる負荷インピーダンス値 R 、 L をそれぞれ V_R 倍、 V_L 倍した。その他のシミュレーション条件は表1と同じである。図14はシミュレーションにより求めた、 V_R と V_L の許容範囲を示す。図14より V_R および V_L の電流制御系の安定性に及ぼす影響はそれぞれ独立と考えられる。 V_R と V_L が境界線より小さいとき本電流制御系は安定である。従って、電流制御系の計算に用いる推定値は、実際の負荷インピー

図 13 誤差の実験結果(学習率変更)

Fig. 13. Experimental results of error (learning rate is changed).

図 14 V_R , V_L の許容範囲
Fig. 14. Stable region of V_R , V_L .

ダンスの推定値より小さめに設定すれば、電流制御系を十分に安定にできることがわかる。

5. ま と め

本論文では、PWM インバータのデジタル電流制御にニューラルネットワークを用い、負荷インピーダンスの変動および制御系の演算遅れによる電流追従性能低下を補償できることを示した。本制御法では、学習に要する時間は 10 サイクル程度で、上記の補償が可能であることがわかった。また、学習後の電流指令値のステップ変化に対しては、含まれる高調波成分が変化しなければ、1 サイクル後には誤差が収束した。更に、学習の安定性について検討を行い、学習率 μ の最適値および上限を明らかにした。負荷インピーダンスの変動については、電流制御系を安定にする変動範囲をシミュレーションにより確認し、その変動範囲が実用上の問題とならないことを示した。

今後の課題としては、

- (1) 負荷インピーダンスの同定アルゴリズムを組込んだ場合の検討
- (2) 速応性の検討

などが挙げられる。

本研究の一部は、内藤科学技術振興財団の援助により行われた。(平成 2 年 7 月 24 日受付)

文 献

- (1) T. Haneyoshi, et al.: "Waveform Compensation of PWM Inverter with Cyclic Fluctuating Loads." Conf. Record of IEEE IAS '86
- (2) 竹田, 他: 「学習制御アクティブフィルタ」, 昭 63 電学全大, No.596
- (3) I. Takahashi & M. Nunokawa: "Prediction Control for a Cycloconverter of a Power Distortion Compensation System", IEEE Trans. Industr. Applic., IA-25, No.2(1989)

- (4) Rumelhart, et al.: Parallel Distributed Processing (1987) MIT Press
- (5) 柴田, 他: 「ニューラルネットワークを適用した PWM インバータのデジタル電流制御」, 平元電学全大, No. 543
- (6) S. ヘイキン: 適応フィルタ入門(昭 62)現代工学社

伊 藤 良 久 (正員)

昭和 40 年 5 月 17 日生。平成 3 年 3 月名古屋大学大学院工学研究科博士課程前期課程修了。同年 4 月ソニー(株)入社, 現在に至る。名古屋大学在学中は主として、ニューラルネットワーク、パワーエレクトロニクスに関する研究に従事。

古 橋 武 (正員)

昭和 29 年 12 月 11 日生。60 年 3 月名古屋大学大学院博士課程修了。同年 10 月(株)東芝入社。府中工場において GTO PWM インバータの研究, 開発に従事。63 年 4 月から名古屋大学工学部電子機械工学科助手, 平成 2 年 12 月同大学助教授, 現在に至る。主として、パワーエレクトロニクス, アドバンスドモーションコントロールおよびニューロファジーに関する研究に従事。計測自動制御学会, IEEE 会員。

大 熊 繁 (正員)

昭和 23 年 2 月 16 日生。47 年名古屋大学大学院修士課程修了。49 年ケース・ウェスタン・リザーブ大学大学院修士課程システム工学専攻修了。52 年名古屋大学大学院博士課程中退。同年同大学工学部助手, 講師を経て 59 年同助教授, 平成 2 年 12 月同教授, 現在に至る。工学博士。主として、パワーエレクトロニクス, ロボティクス, マイクロメカトロニクス, ニューロファジーの研究に従事。計測自動制御学会, 日本ロボット学会, IEEE 会員。

内 川 嘉 樹 (正員)

昭和 16 年 8 月 4 日生。44 年名古屋大学大学院博士課程満了。同年，同大学工学部助手，53 年同助教授を経て 60 年同教授。現在に至る。

工学博士。主として，電子光学および，電子銃の計算

機援用設計，SEM による半導体デバイス診断の研究に従事。61 年日本電子顕微鏡学会論文賞受賞。現在は，CAD，画像処理，信号処理などを対象としたシステム技術の基礎および，産業への応用に関する研究を行っている。日本電子顕微鏡学会，日本ロボット学会，応用物理学会，精密工学会，計測自動制御学会，境界要素法研究会会員。