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の安定性

正員 古 橋 武 (名古屋大)

正員 伊 藤 良 久 (ソニー)

正員 内 川 嘉 樹 (名古屋大)

On Stability of a Digital Current Controller for a PWM Inverter Using a Neural Network

Takeshi Furuhashi, Member (Nagoya University), Yoshihisa Ito, Member (SONY Corp.),
Yoshiki Uchikawa, Member (Nagoya University)

There have been growing demands for high performance in current control of PWM inverters. Digital current controls are becoming dominant in the current controllers of the PWM inverters due to the rapid progress of microprocessor technologies. But the performances of the digital current controllers are degraded by changes of load impedances and delay necessary for calculation of the controllers. The authors proposed a digital current controller for a PWM inverter using a neural network. The new controller could compensate the delay necessary for the calculation and tune the gains of the controller to optimal ones. Stability of the learning of the neural network, however, was not guaranteed in case where the load impedances of the inverter were not exactly known.

This paper presents a method to guarantee the stability of the learning of the neural network. The Lyapunov method is used and the stability condition for the learning rate of the neural network is clarified. Simulations and experiments are done to verify the analytic results.

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。アクティブフィルタをはじめとする多くの用途で高性能の PWM インバータの要求が高まっているが，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著者らはこれまでに，電流制御系にニューラルネットワーク⁽¹⁾を用いることを提案し⁽²⁾，その制御法が負荷インピーダンスの変動および演算遅れを補償で

き，従来の繰返し制御⁽³⁾，学習制御⁽⁴⁾および予測制御⁽⁵⁾に比べて優れていることを示した。文献(2)では，まず負荷インピーダンスを既知としてニューラルネットワークの学習を安定にする学習率の範囲を明らかにし，次に負荷インピーダンスが未知である場合に電流制御系を安定にする負荷インピーダンスの推定値の範囲をシミュレーションにより検討している。文献(2)の例では，電流制御系の計算に用いられる負荷インピーダンスの値が実際の値のおよそ2倍以内であれば電流制御系が安定であることが示されている。そして，実際に上記の計算に用いられる負荷インピーダンス値を推定値よりも小さく設定すれば，大域的な安定性が保証されていないことは実用上それほど問題とはならないことが述べられている。しかし，安定性の

保証がない制御系は理論的に不完全であるばかりでなく、インバータ装置の設置に当たっては、各インバータごとに電流制御系が安定である範囲をシミュレーションもしくは実験により確認しなければならず手数がかかってしまう。安定性の保証は、やはり重要な問題である。

さて、文献(2)ではニューラルネットワークの学習率の検討において負荷インピーダンスの誤差が考慮されておらず、電流制御系の安定性とは別個に検討がなされていた。本来、ニューラルネットワークの学習の安定性は、負荷インピーダンスの誤差をも考慮してなされるべきである。電流制御系の状態を考慮してニューラルネットワークの学習の安定性を保証すれば、電流制御系の安定性は保証される。

本論文では、PWM インバータの電圧指令値と出力電流値から負荷インピーダンス値を同定する方法を示すとともに、安定性の解析をリアプノフ法によって行い、負荷インピーダンスの推定値に誤差がある場合においてもニューラルネットワークの学習の大域的安定性を保証する学習率の範囲を明らかにする。大域的安定性が保証されることで、電流制御系の計算に用いる負荷インピーダンスの推定値を厳密に求める必要がなく、汎用性の高いインバータ装置の製作が可能となる。本制御系の有効性をシミュレーションおよび実験により検証する。

2. 電流制御系

図1は、三相PWM インバータおよびニューラルネットワークによ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。そして、 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 $u_u^*(n)$ 、 $u_v^*(n)$ 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 $u_w^*(n)$ は、 $u_w^*(n) = -u_u^*(n) - u_v^*(n)$ により得る。 T_s はサンプリング周期である。

図2はニューラルネットワークの1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させる。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

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.

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。

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_o 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

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

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。

図3は、図1のシステムの1相分の近似等価回路である。制御系の演算遅れを遅延要素 Z^{-1} で表し、三

図 3 1 相分の等価回路
Fig. 3. Equivalent circuit of one-phase.

角波比較および PWM インバータの部分を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。

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

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

$$e_p(n-2) \equiv v_{p0}^*(n-2) - v_p^*(n-2) \quad \dots\dots\dots (3)$$

と定義する。ただし、\$v_{pq}^*\$ 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

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

となる。ネットの結合係数ベクトル \$\mathbf{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⁽¹⁾により更新する。

$$\mathbf{h}_{p(n)} = \mathbf{h}_{p(n-2)} + \mu e_p(n-2) \mathbf{i}_p^*(n-2) \quad \dots\dots\dots (5)$$

ここで、\$\mu\$: 学習率

学習が安定であるための学習率 \$\mu\$ の範囲は、文献(2)では

$$0 < \mu < \frac{2}{N I_e^{*2}} \quad \dots\dots\dots (6)$$

であり、\$\mu\$ の最適値は \$1/(N I_e^{*2})\$ と与えられていた。ただし、\$N\$ は 1 周期間のサンプル回数であり、\$I_e^*\$ は電流指令値の実効値である。

3. 負荷インピーダンスの同定

文献(2)では、負荷インピーダンス値がわかっているとしてニューラルネットワークの学習を安定にする学習率 \$\mu\$ の範囲を示した。しかし、負荷インピーダ

図 4 パラメータ同定機構を含む 1 相分の等価回路

Fig. 4. Equivalent circuit with parameter estimation scheme.

ンスは例えば熱などの影響で時間とともに変化し、またアクティブフィルタへの応用を考えた場合には、系統インピーダンスの変動の影響を受ける。これまでは、負荷インピーダンスの推定値に誤差がある場合には、ニューラルネットワークの学習の安定性は保証されていなかった。文献(2)では、電流制御系を安定にする負荷インピーダンスの推定値の許容範囲をシミュレーションにより求めた。本インバータ装置の設置にあたっては、負荷インピーダンスの変動範囲を十分に把握したうえで、シミュレーションもしくは実験により安定な範囲を確認し、電流制御系の計算に用いる負荷インピーダンス値を設定する必要があった。

本章では、ニューラルネットワークの学習の大域的安定性を保証することを目指して、まず負荷インピーダンスの同定手法を示す。ニューラルネットワークの出力である電圧指令値 \$v_p^*(n)\$ とインバータの出力電流 \$i_p(n)\$ の関係は、(2)式より

$$v_p^*(n-2) = \alpha i_p(n) + \beta i_p(n-1) \quad \dots\dots\dots (7)$$

となる。これより(8)式の関係が得られる。

$$\begin{bmatrix} \hat{\alpha}(n) \\ \hat{\beta}(n) \end{bmatrix} = \begin{bmatrix} i_p(n) & i_p(n-1) \\ i_p(n-1) & i_p(n-2) \end{bmatrix}^{-1} \begin{bmatrix} v_p^*(n-2) \\ v_p^*(n-3) \end{bmatrix} \quad \dots\dots\dots (8)$$

ただし、\$\hat{\alpha}(n)\$, \$\hat{\beta}(n)\$ は真値にノイズを含んだ値である。この \$\hat{\alpha}(n)\$, \$\hat{\beta}(n)\$ を用いて推定値 \$\bar{\alpha}(n)\$, \$\bar{\beta}(n)\$ を(9)式で表される一次遅れフィルタにより更新する。

$$\begin{aligned} \bar{\alpha}(n+1) &= \bar{\alpha}(n) + \xi(\hat{\alpha}(n) - \bar{\alpha}(n)) \\ \bar{\beta}(n+1) &= \bar{\beta}(n) + \xi(\hat{\beta}(n) - \bar{\beta}(n)) \end{aligned} \quad \dots\dots\dots (9)$$

ただし、\$\xi = 1 - \exp(-T_s/T_i)\$ で与えられる。\$T_s\$ はサンプリング周期、\$T_i\$ は一次遅れフィルタの時定数である。(8)式の演算によって得られる \$\bar{\alpha}\$, \$\bar{\beta}\$ は大きな雑音を含んでいるので、フィルタ効果を持たせるために \$\xi\$ は小さな正の値とする。

パラメータ \$\alpha, \beta\$ の推定機構を含んだ 1 相分の等価回路を図 4 に示す。

4. 学習の安定性

本章では、前章の負荷インピーダンスの同定手法を用いて、ニューラルネットワークの学習の大域的安定性を保証する学習率 μ の範囲をリアプノフの手法を用いて明らかにする。誤差を含んだ負荷インピーダンスの推定値が前章の手法により徐々に補正されていくものとする。そこで、負荷インピーダンスより求められるパラメータ $\hat{\alpha}$, $\hat{\beta}$ が(10)式で表されるとする。

$$\left. \begin{aligned} \hat{\alpha}_{(n)} &= \alpha + \Delta\alpha_{(n)} \\ \hat{\beta}_{(n)} &= \beta + \Delta\beta_{(n)} \end{aligned} \right\} \dots\dots\dots (10)$$

ここで、 $\Delta\alpha_{(n)}$, $\Delta\beta_{(n)}$ はそれぞれ推定値 $\hat{\alpha}_{(n)}$, $\hat{\beta}_{(n)}$ の真値 α , β との誤差である。このとき、(4)式の誤差 $e_{p(n)}$ は(11)式で置き換えられる。

$$\begin{aligned} e_{p(n-2)} &= \alpha(i_p^*_{(n)} - i_{p(n)}) \\ &\quad + \beta(i_p^*_{(n-1)} - i_{p(n-1)}) \\ &\quad + \Delta\alpha_{(n-2)}(i_p^*_{(n)} - i_{p(n)}) \\ &\quad + \Delta\beta_{(n-2)}(i_p^*_{(n-1)} - i_{p(n-1)}) \\ &\quad \dots\dots\dots (11) \end{aligned}$$

(3), (4)式を用いることにより、(11)式は

$$\begin{aligned} e_{p(n-2)} &= v_{p0}^*_{(n-2)} - v_{p(n-2)} \\ &\quad + \Delta\alpha_{(n-2)}e_{i(n)} + \Delta\beta_{(n-2)}e_{i(n-1)} \\ &\quad \dots\dots\dots (12) \end{aligned}$$

となる。ただし、 $e_{i(n)}$ は電流指令値 $i_p^*_{(n)}$ と出力電流 $i_{p(n)}$ の誤差である。更に、(1)式を代入して

$$\begin{aligned} e_{p(n-2)} &= i_p^*_{(n-2)}^T(h_{p0} - h_{p(n-2)}) \\ &\quad + \Delta\alpha_{(n-2)}e_{i(n)} + \Delta\beta_{(n-2)}e_{i(n-1)} \\ &\quad \dots\dots\dots (13) \end{aligned}$$

となる。ここで、 h_{p0} はニューラルネットの望ましい出力 v_{p0}^* を実現するニューラルネットの結合係数ベクトルである。(13)式を(5)式に代入すると(14)式が得られる。

$$\begin{aligned} h_{p(n)} &= h_{p(n-2)} + \mu i_p^*_{(n-2)}^T \\ &\quad \times (h_{p0} - h_{p(n-2)}) i_p^*_{(n-2)} \\ &\quad + \mu(\Delta\alpha_{(n-2)}e_{i(n)} + \Delta\beta_{(n-2)}e_{i(n-1)}) i_p^*_{(n-2)} \\ &\quad \dots\dots\dots (14) \end{aligned}$$

結合係数誤差ベクトル $C_{p(n)}$ を

$$C_{p(n)} \equiv h_{p(n)} - h_{p0} \dots\dots\dots (15)$$

と定義すると、(14)式より

$$\begin{aligned} C_{p(n)} &= C_{p(n-2)} - \mu i_p^*_{(n-2)} i_p^*_{(n-2)}^T C_{p(n-2)} \\ &\quad + \mu \Delta_{(n-2)}^T e_{i(n-2)} i_p^*_{(n-2)} \\ &= S_{p(n-2)} C_{p(n-2)} \\ &\quad + \mu \Delta_{(n-2)}^T e_{i(n-2)} i_p^*_{(n-2)} \dots\dots\dots (16) \end{aligned}$$

となる。ここで、

$$\left. \begin{aligned} \Delta_{(n)}^T &= (\Delta\alpha_{(n)} \quad \Delta\beta_{(n)}) \\ e_{i(n-2)}^T &= (e_{i(n)} \quad e_{i(n-1)}) \\ S_{p(n-2)} &= I - \mu i_p^*_{(n-2)} i_p^*_{(n-2)}^T \end{aligned} \right\} \dots\dots\dots (17)$$

$S_{p(n)}$ を誤差遷移行列と呼ぶ。パラメータ誤差がないとき、つまり $\Delta=0$ のとき、結合係数ベクトル $C_{p(n)}$ の収束は $S_{p(n)}$ による。

ここで、(18)式で表されるリアプノフ関数 $V_{(n)}$ を定義する。

$$V_{(n)} = C_{p(n)}^T C_{p(n)} + \frac{1}{\xi} \Delta_{(n)}^T \Delta_{(n)} \dots\dots\dots (18)$$

このリアプノフ関数は、ニューラルネットワークの結合係数の誤差[(15)式]およびパラメータ誤差[(17)式]を含み、本関数を減少させる学習 μ により、ニューラルネットワークの学習を安定にできる。

さて、(8)式によって得られるパラメータ $\hat{\alpha}_{(n)}$, $\hat{\beta}_{(n)}$ が含む雑音の影響は、(9)式において ξ を十分に小さくすることによりフィルタリングされる。そこで、(9)式において

$$\left. \begin{aligned} \hat{\alpha}_{(n)} &= \alpha \\ \hat{\beta}_{(n)} &= \beta \end{aligned} \right\} \dots\dots\dots (19)$$

としても(9)式の結果は変わらない。更に技巧的ではあるが、パラメータ $\hat{\alpha}_{(n)}$, $\hat{\beta}_{(n)}$ の更新を2サンプルおきに行うことにする[(9)式において左辺の $n+1$ を $n+2$ とする]と、(9)式は

$$\begin{aligned} \alpha - \hat{\alpha}_{(n+2)} &= \alpha - \hat{\alpha}_{(n)} - \xi(\alpha - \hat{\alpha}_{(n)}) \\ \beta - \hat{\beta}_{(n+2)} &= \beta - \hat{\beta}_{(n)} - \xi(\beta - \hat{\beta}_{(n)}) \end{aligned}$$

と変形できる。上式に(10)式を代入すると

$$\left. \begin{aligned} \Delta\alpha_{(n+2)} &= \Delta\alpha_{(n)} - \xi\Delta\alpha_{(n)} \\ \Delta\beta_{(n+2)} &= \Delta\beta_{(n)} - \xi\Delta\beta_{(n)} \end{aligned} \right\} \dots\dots\dots (20)$$

となる。更には(17)式を用いて上式は

$$\Delta_{(n+2)} = \Delta_{(n)} - \xi\Delta_{(n)} \dots\dots\dots (21)$$

と表現される。

以上の準備のもとに以下のリアプノフ関数の差分を求める。

$$\Delta V_{(n)} \equiv V_{(n)} - V_{(n-2)} \dots\dots\dots (22)$$

(18)式を(22)式に代入することにより

$$\begin{aligned} \Delta V_{(n)} &= C_{p(n)}^T C_{p(n)} + \frac{1}{\xi} \Delta_{(n)}^T \Delta_{(n)} \\ &\quad - C_{p(n-2)}^T C_{p(n-2)} - \frac{1}{\xi} \Delta_{(n-2)}^T \Delta_{(n-2)} \\ &\quad \dots\dots\dots (23) \end{aligned}$$

となる。(23)式の右辺の第1項と第2項にそれぞれ(16)式と(21)式を代入して整理すると

$$\begin{aligned} \Delta V_{(n)} &= -(C_{p(n-2)}^T \quad \Delta_{(n-2)}^T) \\ &\quad \times \begin{bmatrix} A & B \\ C & D \end{bmatrix} \begin{bmatrix} C_{p(n-2)} \\ \Delta_{(n-2)} \end{bmatrix} \dots\dots\dots (24) \end{aligned}$$

$$\begin{cases} A = I - S_{p(n-2)}^T S_{p(n-2)} \\ B = -\mu S_{p(n-2)}^T i_p^*(n-2) e_{i(n-2)}^T \\ C = -\mu e_{i(n-2)} i_p^*(n-2)^T S_{p(n-2)} \\ D = (2-\xi)I - \mu^2 e_{i(n-2)} e_{i(n-2)}^T N I_e^{*2} \end{cases}$$

となる。このリアプノフ関数の差分が常に正にならない（準負定である）ことを保証できれば、ニューラルネットの学習は安定である。さて、(24)式は $(C_{p(n-2)}^T A_{(n-2)}^T)$ に関する二次形式である。そこで、 $\Delta V_{(n)}$ が準負定であるためには、行列

$$\begin{bmatrix} A & B \\ C & D \end{bmatrix} \dots\dots\dots (25)$$

の主部分行列の行列式がすべて非負となればよい⁽⁶⁾。この条件を満たす学習率 μ の範囲は次のようになる。

$$0 < \mu < \frac{2(2-\xi)}{(2-\xi)N I_e^{*2} + e_{i(n-2)}^T e_{i(n-2)}} \dots\dots\dots (26)$$

(25)式の主部分行列の行列式をすべて求めることは一見困難にみえる。しかし、部分行列 A が $i_p^* i_p^{*T}$ の行列からなりその階数が1であること、 B, C はたがいに転置の関係にあることを考慮すれば、(25)式の行列の階数は大きくとも3であり、ほとんどの主部分行列の行列式は簡単な考察により零であることがわかる。

(26)式はニューラルネットワークの学習率 μ の安定条件を与える。出力電流誤差 $e_{i(n-2)}$ が大きいほど学習率 μ が小さく抑えられ、出力電流誤差の大きい学習初期および負荷インピーダンスがステップ的に大きく変化した場合に発散を抑える効果がある。パラメータ誤差を考慮しない(6)式の場合では、 μ が同式の中間の値のとき学習が最も速く収束していた。また、 e_i が零のとき(26)式は(6)式と一致する。そこで、学習率 μ は(26)式の範囲の中間付近においてほぼ最適と思われる。すなわち、

$$\mu = 0.5 \frac{2(2-\xi)}{(2-\xi)N I_e^{*2} + e_{i(n-2)}^T e_{i(n-2)}} \dots\dots\dots (27)$$

とする。式中の I_e^{*2} は電流指令値の実効値の二乗であり、PWMインバータの定格電流の実効値の二乗とすればよい。また、 e_i は(17)式で与えられ、現時点の出力電流誤差と1サンプル前の誤差から計算される。また、 ξ はパラメータ同定器の雑音除去能力を考慮することによって決定される。

5. シミュレーションと実験

以上の解析の結果をシミュレーションと実験により

図5 実験装置構成
Fig. 5. Configuration of experimental system.

表1 シミュレーションおよび実験条件
Table 1. Conditions of simulation and oxperiment.

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_{oc}	270 V
入力層のユニット数	N	30

検証する。

実験システムの構成を図5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 $v_p^*(n)$ を読み出して三角波の PWM キャリア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 (8)、(9)式で表される負荷インピーダンス同定の演算、(4)式で表される誤差信号の演算、(27)式の学習率 μ の演算、(1)、(5)式で表されるニューラルネットワークの演算を以上の順に行う。

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

図 6 シミュレーション結果 (旧手法)
Fig. 6. Simulation results (old method).

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。

$$i_u^* = 3.5 \times \{ \sin \omega t + (1/5) \sin 5\omega t + (1/7) \sin 7\omega t \} \quad (\text{A}) \quad \dots\dots\dots (28)$$

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。

まず，第 3 章，第 4 章で示したニューラルネットワークの学習の大域的安定性を保証する手法の検証を行う。

図 6 は，図 4 の近似等価回路における学習 1 回目の出力電流波形のシミュレーション結果である。 U 相の出力電流指令値 i_u^* に対して出力電流 i_u は大きくずれ，たちまちのうちに発散している。なお，負荷インピーダンスの推定値を $\hat{R}=3R$ ， $\hat{L}=3L$ と大きくずらし，学習率 μ を旧手法である (6) 式の最適値 $[1/(Nl_e^*2)]$ に設定している。結合荷重ベクトルの初期値 $h_{p(0)}$ は 0 としている。また，(9) 式のフィルタ定数は (8) 式のパラメータ推定値 $\hat{\alpha}$ ， $\hat{\beta}$ に含まれる雑音を十分に除去できるように $\xi=0.001$ (フィルタ時定数 $T_f \approx 0.66 \text{ s}$) とした。

図 7 は図 4 の近似等価回路を用いて，学習率 μ を新手法である (27) 式の値にし，ほかは図 6 と同じ条件にした場合のシミュレーション結果である。図 7 (a) は学習開始後 1 回目と 50 回目の U 相の出力電流指令値 i_u^* と出力電流 i_u を示す。(b) 図は出力電流の誤差 E の推移を示す。誤差 E は次式で定義する。

$$E = \sum_{n=1}^N \{ i_u^*(n) - i_u(n) \}^2 \quad \dots\dots\dots (29)$$

誤差 E は，各周期における，サンプリングごとの出力電流誤差の二乗和である。なお，学習は電流指令値の 1 周期を 1 回としている。図 6 では出力電流はたち

(a) 出力電流

(b) 誤差

図 7 シミュレーション結果 (新手法)
Fig. 7. Simulation results (new method).

まち発散しているが，図 7 では，出力電流は負荷インピーダンスの推定値が大きくずれているために，大きな誤差を生じているものの発散せず，その後指令値に一致している。

図 7 は一例にすぎないが，負荷インピーダンスの推定値が実際の値とどれだけ離れていても，新手法による学習は安定である。図 4 の近似等価回路では，インバータ回路の制約がないのでどのような電流をも流すことができ，このことを確認できる。実際のインバータにおいては，出力電流の過電流保護などの制約を受ける。

次に，(26) 式の学習率 μ の範囲の妥当性を検証するシミュレーションを行った。図 8 は図 4 の近似等価回路において， μ を (26) 式の上限付近に設定したときの出力電流誤差の推移を示す。今回は，負荷インピーダンスの推定値に誤差はない ($\hat{R}=R$ ， $\hat{L}=L$) のとした。これは，負荷インピーダンスの推定値に誤差があると，その影響が出力電流の誤差に大きく現れてしまい，学習率 μ の設定の影響を見えにくくしてしまうことによる。また，結合荷重ベクトルの初期値

(a) $\mu=1.01$ 倍(学習率の上限)

(b) $\mu=0.99$ 倍(学習率の上限)

図 8 シミュレーション結果 (学習率の範囲の検証)

Fig. 8. Simulation results (verification of range of learning rate).

$h_{p(0)}$ は零とした。図 8 (a)は学習率 μ を(26)式の上限の 1.01 倍とし、(b)図は 0.99 倍としている。学習率 μ の上限を境にして安定・不安定が分かれていることがわかる。また μ の下限については、 μ が零では学習が行われず、更に負では結合荷重の更新の方向が反対となるので、明らかに零が μ の下限であることがわかる。

ここで、(9)式のパラメータ ξ と学習の安定性の関係について考察する。 ξ を大きくするとフィルタの時定数は小さくなり、負荷インピーダンスの同定を速く行うことができる。しかし、このことはフィルタリングの効果を減じ、(19)式における仮定を成り立たなくしてしまい、ニューラルネットの学習の安定性を保証できなくなる。 ξ は出力電流に含まれるスイッチングリプルを十分に吸収できるような小さな値とする必要がある。一方、小さな ξ では、負荷インピーダンスの同定が遅くなり、学習の収束が図 7 の例のように遅くなってしまいが、実運用上において図 7 の例のように負荷インピーダンスの推定値が 3 倍もずれること

(a) 出力電流

(b) 誤差

図 9 シミュレーション結果 (等価回路)

Fig. 9. Simulation results (equivalent circuit).

は考え難い。数十パーセントのずれであれば、後に示すように学習の収束に要する時間は負荷インピーダンスの推定値が正しいときとほとんど差はない。

本論文で述べる手法により、ニューラルネットワークの学習の安定化が実現されていることがわかったので、次に制御対象を図 4 の近似等価回路から図 1 の PWM インバータとした場合について、シミュレーションと実験の比較を行った。シミュレーションおよび実験条件は表 1 の条件と同じである。また、フィルタ定数 $\xi=0.001$ とした。

図 9～図 11 は、それぞれ学習率 μ を(27)式の値にし、 R, L の推定値 $\hat{R}, \hat{L}$ を真値の 1.5 倍 ($\hat{R}=1.5R, \hat{L}=1.5L$)とした場合の結果である。結合荷重ベクトルの初期値 $h_{p(0)}$ は 0 である。 $\hat{R}, \hat{L}$ が適当な値に設定されることにより(4)式から誤差信号が計算され、(5)式からニューラルネットワークの結合荷重が更新されて、次に(1)式より出力電圧指令値が生成され出力電流が流れる。

この出力電流を用いて、(8)、(9)式により負荷インピーダンスの推定値 $\hat{\alpha}, \hat{\beta}$ が補正される。各図は、1 周期を 1 回として 30 回学習を繰返したときのシミ

(a) 出力電流

(b) 誤差

図 10 シミュレーション結果 (PWM インバータ)

Fig. 10. Simulation results (PWM inverter).

シミュレーションおよび実験の結果を示す。

図 9 が図 4 の近似等価回路の場合で、図 10 が図 1 の PWM インバータの場合のシミュレーション結果である。

学習開始後 1 回目と 15 回目の U 相の出力電流指令値 i_u^* と出力電流 i_u の波形も併せて示す。PWM インバータの場合では、出力電流波形に PWM 制御によるリップルが見られるが、両図の結果はよく一致している。また、出力電流の誤差は、負荷インピーダンスの推定値に誤差があるにもかかわらず、文献(2)の負荷インピーダンスの推定値に誤差がないときの結果とほぼ同程度の速さで収束している。

図 11 は図 5 の PWM インバータを用いた実験装置による実験結果である。電流波形はサンプル点のデータを直線で補間したものである。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。実験では、三角波比較の回数が少ないために小さな誤差が残っている。また、1 回目の波形において実験波形に若干の相違が見られるが、これは主に実験に用いたリ

(a) 出力電流

(b) 誤差

図 11 実験結果

Fig. 11. Experimental results.

アクトルの周波数特性があまりよいものではなかったことによる。

6. まとめ

本論文では、ニューラルネットワークを用いたディジタル電流制御系において、ニューラルネットワークの学習の大域的安定性を保証する学習率 μ の範囲を明らかにした。学習の安定性が保証されない段階では、本インバータ装置の設置にあたって、負荷インピーダンスの変動範囲を十分に把握したうえでシミュレーションもしくは実験により安定な範囲を確認し、電流制御系の計算に用いる負荷インピーダンス値を設定する必要があった。ニューラルネットワークの学習の安定性が保証されたことで、負荷インピーダンスは概略値がわかるだけでよく、汎用性の高いインバータ装置を実現できる。

今後の課題としては、

- (1) アクティブフィルタへの応用の検討
- (2) 電流制御系の速応性の改善

などが挙げられる。

(平成 4 年 2 月 19 日受付, 同 4 年 6 月 25 日再受付)

文 献

- (1) Rumelhart, et al.: "Parallel Distributed Processing", The MIT Press
- (2) 伊藤, 他: 「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」, 電学論 D, 111, 433 (平 3-6)
- (3) T. Haneyoshi, et al.: "Waveform Compensation of PWM Inverter with Cyclic Fluctuating Loads," Conf, Record of IEEE/IAS '86
- (4) 竹田, 他: 「学習制御アクティブフィルタ」, 昭 63 電気学会全大, No. 596
- (5) I. Takahashi & M. Nunokawa: "Prediction Control for a Cycloconverter of a Power Distortion Compensation System," *IEEE Trans. Industr. Applic.*, 25, No. 2 (1989)
- (6) G. ストラング: 「線形代数とその応用」産業図書

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 4 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, ファジ理論, ニューラルネットワーク, AI に関する研究に従事。日本ファジィ学会, 計測自動制御学会, IEEE 会員。

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。

内 川 嘉 樹 (正員)

昭和 16 年 8 月 4 日生。39 年名古屋大学工学部電子工学科卒業。44 年同大学大学院博士課程満了。工学博士。同年, 名古屋大学工学部助手, 53 年同助教授を経て 60 年同教授, 現在に至る。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。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。61 年日本電子顕微鏡学会論文賞受賞。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。