PID 型ニューロコントローラによる 電気自動車試験装置のトルク制御

正員 松村 茂 憲 (徳島大)

正員 大松 繁 (徳島大)

正員 樋笠 博 正 (四国総研)

Torque Control of Electric Vehicle Testing System by Neuro-PID Controller

Shigenori Matsumura, Member, Sigeru Omatu, Member (University of Tokushima), Hiromasa Higasa, Member (Shikoku Research Institute Inc.)

For the purpose of developing an efficient driving system of electric vehicles (EVs), a testing system using motors has been devised, which enables us to simulate the driving performance of EVs to be simulated. In this system, running resistance of the EV is realized by torque control of the motor operated as a generator. Nowadays, torque control is performed by using conventional PID controllers, and reasonably good results can be obtained. However, when using conventional PID controllers, it generally needs much effort and time to tune the PID gains.

In this paper, in order to avoid the above problems and improve the performance of torque controllers, a method is proposed by using neural networks. At first, the testing system and its conventional PID controller are explained. Then a neuro-controller is described to tune the PID controller gains. Finally, applying the neuro-controller to the real testing system, we examine the effectiveness of the proposed algorithm.

キーワード：ニューロコントローラ，PID 制御，10 モード走行パターン，トルク制御，電気自動車試験装置

1. はじめに

現在，大気汚染ならびに地球温暖化などの点から，従来のエンジン自動車の代わりに電気自動車（以下，EV と略記）が見直されはじめている。EV ではその電源として，エネルギー密度の低い電池が用いられているため，一充電走行距離が短いという欠点がある。この場合，電池や電動機に対し加速や走行方法によっては，その走行距離がいつそう短くなることが予想され，EV の利用面での問題点である。このため，EV の電源・駆動系に関する電池の効率的な運用方法や電動機の効率的な駆動方法についての研究が重要である。

そこで，著者らは既に，実験室内で種々の走行条件

下における EV の走行を模擬し，電池や電動機の稼働効率を測定することを目的とした EV 試験装置を構築した⁽¹⁾。本装置では EV の走行抵抗トルクは，電動機を発電機として運転し，その負荷トルクで模擬されている。ただし，負荷トルクは従来の PID 制御によって制御され，その PID ゲインは実機を繰り返し運転制御することによって決定されている。このような試行錯誤で得られた PID ゲインが精度の点で果たして最適に近い値となっているか否かについて，検討すべき問題が残されている。

ニューラルネットワーク（以下，NN と略記）を用いるニューロコントローラ（以下，NC と略記）は，非線形制御および学習制御が可能となる優れた制御手段の一つである⁽²⁾。このような特性を有している NC

を実現する一方式として、PID ゲインをセルフチューニングする方法が考察されている⁽³⁾⁽⁴⁾。文献(3)では、望ましい PID ゲインをあらかじめ与えて、それを NN で学習させるパターン認識型チューニング手法が報告されている。また、著者らは望ましい教師パターンを必要としないセルフチューニング PID 型 NC を文献(4)で提案し、その有効性をシミュレーションによって検証した。それゆえ、著者らが提案した NC を実際の EV 試験装置へ適用することによって、NC が PID ゲインをオンライン学習し、望ましい走行抵抗トルク値を精度良く実現可能となることが期待できる。この結果、EV 試験装置により、実際の EV を効率良く稼働させるための精度の良い検討が可能となってくる。

そこで本論文では、EV 試験装置（以下、試験装置と略記）の走行抵抗トルク制御系（以下、トルク制御系と略記）の PID ゲインを決定するために、NN を組み込んだ NC を構成し、その有効性を実機で実験的に検証する。

まず、制御対象となる試験装置の概要とその走行抵抗トルクを実現する負荷用電動機のトルク制御系について述べる。次に、このトルク制御系に対して NN を用いたセルフチューニング PID 型 NC を設計する。ただし、制御対象は回帰式と NN を用いてモデル化する。最後に、実機運転へ本論文で提案した NC を適用し、既に報告した単一走行パターンに対する有効性⁽⁴⁾のみならず、複雑な走行パターンに対応したトルク制御に対しても、本論文で考察する NC が有効であることを示す。

2. 試験装置の概要

本論文で用いる試験装置の主要な構成を図 1 に示す。試験装置は、直流電動機(DCM)、誘導電動機(ACM)およびパソコン(UFAS)を介した制御・計測装置からなっている。EV の走行抵抗は電動機(M1)を発電機として運転し、その負荷トルクを EV の走行パターンに応じたトルク値に制御することにより模擬している。また EV の走行は駆動用電動機(M2)を EV の走行パターンに応じた回転数で運転することにより模擬している。

本論文の実験において想定した車両モデルおよび走行パターンは以下のようなものである。

(i) 車両モデル このモデルは重量が約 1,000 kg の普通乗用車クラスの EV で、電動機 4 台を搭載した車両の 1/4 モデルである。

(ii) 走行パターン エンジン自動車の排ガス測

図 1 EV 試験装置の構成
 Fig. 1. Structure of EV testing system.

図 2 走行パターン
 Fig. 2. Driving pattern.

定に使用される 10 モード走行パターン⁽⁵⁾を準用したもので、図 2 に示すような走行パターンである。文献(4)で述べた単一走行パターンは、図 2 における前半の加速、定速、減速、停止の 4 モードからなる走行パターンである。本論文では、これに 7 モードを加えた 11 モードの走行パターンを適用する。

3. 負荷用電動機のトルク制御

前章の試験装置におけるトルク制御系の構成図を図 3 に示す。ここで EV システムは、負荷として用いる電動機 DCM(M1)と付属のコントローラ DDC(M1)より構成されている。更に、DDC への制御入力パソコン(UFAS)を介した PID 演算により調整される。実機を用いた試行錯誤の結果、PID 部は I 動作のみとし、そのゲインは 0.7 とした。また制御対象のみのステップ応答例を図 4 に示す。この結果、制御対象の時定数は 0.2 秒以下であり、整定時間は 0.5 秒程度であることがわかる。次に、この制御系を用いて第 2 章で述べた EV の走行パターンを模擬した場合の実測例を図 5 に示す。同図からわかるように、制御対象の入出

図 3 PID トルク制御系
Fig. 3. PID torque control system.

図 4 ステップ応答例
Fig. 4. Example of step response.

図 5 PID トルク制御例
Fig. 5. Example of PID torque control.

力ゲインが、特に出力の正と負の違いにより相違している。このことから、対象とするシステムには、非線形要素が介在していることがわかる。従って、出力を目標値に追従させるためには、何らかの非線形補償を行うことが必要である。

4. NC によるトルク制御系の設計

通常の PID 制御系の設計では、PID ゲインは実機運転による試行錯誤を通して決定されており、それによってもある程度の制御性能は得られている。しかし、試行錯誤に要する時間と労力は多大であり、しかもオフライン的に決定されている。

そこで、図 6 に示すような NN を用いた制御系を構成し、PID ゲインの適切な値へのチューニングをオンライン的に行い、その制御性能の改善を図る。

図 6 NN によるトルク制御系
Fig. 6. Torque control system by NN.

制御系は制御対象と直列に接続した PID 制御機構部と並列に接続したモデル部とから構成されている。更に、PID 制御機構部は、PID ゲインを出力する NN(NN(1))とそれらのゲインを用いて制御入力 of the演算を行う部分(PID)とからなっている。また、モデル部は回帰式と NN(NN(2))とからなっている。ただし、NN(2)は回帰式のみで近似し得ない部分を補正するためのものである。

〈4・1〉 PID 制御機構⁽⁶⁾

(1) PID 制御 図 6 に示す PID 演算部の計算式は、従来の PID ゲインが一定の場合の計算式から次式となる。

$$\left. \begin{aligned} u(k) &= u(k-1) + \{K_P(k) + K_I(k) + K_D(k)\} \\ &\quad \times E(k) - \{K_P(k) + 2K_D(k)\} \\ &\quad \times E(k-1) + K_D(k)E(k-2) \\ K_P(k) &= C_1 O_P(k), K_I(k) = C_I O_I(k), \\ K_D(k) &= C_D O_D(k) \end{aligned} \right\} \dots\dots\dots (1)$$

$$E(k) = r(k) - y(k) \dots\dots\dots (2)$$

ここで、 $u(k)$: コントローラ出力、 $K_P(k)$ 、 $K_I(k)$ 、 $K_D(k)$: 比例、積分、微分の各ゲイン、 $O_P(k)$ 、 $O_I(k)$ 、 $O_D(k)$: NN(1)の出力、 C_I : スケール調整定数、 $r(k)$: トルク設定値、 $y(k)$: 実機のトルク出力

また、 $u(k) = u(kT)$ とし、他の変数の表示についても同様とする。ただし、 T はサンプリング周期を示している。

(2) NCの構成法 NN(1)の構造は3層の階層構造とし、入力層のユニット数は1、中間層のユニット数は3、出力層のユニット数はPID各ゲインを出力するため3とする。これらユニットの出力関数は次式とする。

$$f(x) = \{1 - \exp(-gx)\} / \{1 + \exp(-gx)\} \quad (\text{中間層}) \quad (3)$$

$$f(x) = x \quad (\text{出力層}) \quad (4)$$

ただし、 g : ダイナミックゲイン、 x : ユニットの総和

NN(1)の学習はバックプロパゲーション法により行い、次式に示す評価関数を最小化するものとする。

$$\left. \begin{aligned} J &= e_r(k)^2 / 2 \\ e_r(k) &= C_2 \{r(k) - y(k)\} \end{aligned} \right\} \quad (5)$$

ただし、 C_2 : スケール調整定数

本論文で考察する制御対象におけるサンプリング時刻 k と設定値 $r(k)$ 、制御入力 $u(k)$ 、出力 $y(k)$ 、偏差 $E(k)$ および出力誤差 $e_r(k)$ の関係を図7に示す。この定式化では、設定値 $r(k)$ が急変すると $e_r(k)$ が急激に変化する。これを抑制するために、ここでは $r(k)$ の代わりに $r(k-1)$ を用い、 $e_r(k)$ を次式のように設定した。

$$e_r(k) = C_2 \{r(k-1) - y(k)\} \quad (6)$$

この場合、NN(1)の重みを修正するために用いる評価関数 J の勾配は以下の各式により計算される。

$$\begin{aligned} \partial J / \partial W_{ij}^l(k-1) &= e_r(k) \cdot \partial e_r(k) / \partial W_{ij}^l(k-1) \\ &= -C_2 e_r(k) \cdot \partial y(k) / \partial W_{ij}^l(k-1) \end{aligned} \quad (7)$$

ここで、 $W_{ij}^l(k-1)$: 時刻 $k-1$ における $l-1$ 層 j 番ユニットと l 層 i 番ユニットの結合の重み

図7 制御演算タイムフロー

Fig. 7. Time flow of control signal calculating.

$$\begin{aligned} \partial y(k) / \partial W_{ij}^l(k-1) \\ = \partial y(k) / \partial u(k-1) \cdot \partial u(k-1) / \partial W_{ij}^l(k-1) \end{aligned} \quad (8)$$

ただし、(8)式の第1項 $\partial y(k) / \partial u(k-1)$ は次節で作成するモデルを用いて求める $\partial \hat{y}(k) / \partial u(k-1)$ によって代用する。すなわち、 $\hat{y}(k) = [\text{NN}(2) \text{出力} + \text{回帰式}]$ より $\partial \hat{y}(k) / \partial u(k-1)$ は、NN(2)出力と回帰式の和の勾配として求めることとする。

(8)式の第2項 $\partial u(k-1) / \partial W_{ij}^l(k-1)$ は、次式で求められる。

$$\begin{aligned} \partial u(k-1) / \partial W_{ij}^l(k-1) \\ = \partial u(k-1) / \partial \mathbf{K}(k-1) \\ \times \partial \mathbf{K}(k-1) / \partial W_{ij}^l(k-1) \end{aligned} \quad (9)$$

ここで、 $\mathbf{K}(k-1) = \{K_P(k-1), K_I(k-1), K_D(k-1)\}^t$ であり、NN(1)の出力を表している。次式で与えられる(9)式の第2項は、NN(1)に関するバックプロパゲーション法により求めることができる。

$$\begin{aligned} \partial \mathbf{K}(k-1) / \partial W_{ij}^l(k-1) \\ = \{ \partial K_P(k-1) / \partial W_{ij}^l(k-1), \\ \partial K_I(k-1) / \partial W_{ij}^l(k-1), \\ \partial K_D(k-1) / \partial W_{ij}^l(k-1) \}^t \end{aligned} \quad (10)$$

また、(9)式の第1項 $\partial u(k-1) / \partial \mathbf{K}(k-1) = \{u_{a1}(k-1), u_{a2}(k-1), u_{a3}(k-1)\}$ の各成分は(1)式を用いて以下のように計算される。

$$\begin{aligned} u_{a1}(k-1) &= \partial u(k-1) / \partial K_P(k-1) \\ &= E(k-1) - E(k-2) \end{aligned} \quad (11)$$

$$\begin{aligned} u_{a2}(k-1) &= \partial u(k-1) / \partial K_I(k-1) = E(k-1) \end{aligned} \quad (12)$$

$$\begin{aligned} u_{a3}(k-1) &= \partial u(k-1) / \partial K_D(k-1) \\ &= E(k-1) - 2E(k-2) + E(k-3) \end{aligned} \quad (13)$$

以上の(6)~(13)式から、評価関数のNN(1)の重みに関する勾配は次式のように整理される。

$$\begin{aligned} \partial J / \partial W_{ij}^l(k-1) \\ = -C_2^2 \{r(k-1) - y(k)\} \partial y(k) / \partial u(k-1) \\ \times \{ u_{a1}(k-1) \partial K_P(k-1) / \partial W_{ij}^l(k-1) \\ + u_{a2}(K-1) \partial K_I(k-1) / \partial W_{ij}^l(k-1) \\ + u_{a3}(K-1) \partial K_D(k-1) / \partial W_{ij}^l(k-1) \} \end{aligned} \quad (14)$$

この $\partial J / \partial W_{ij}^l(k-1)$ を用いて重みの修正は次式により行う。

$$\begin{aligned} \Delta W_{ij}^l(k-1) &= -\varepsilon \cdot \partial J / \partial W_{ij}^l(k-1) \\ &+ \alpha \Delta W_{ij}^l(k-2) + \beta W_{ij}^l(k-3) \end{aligned} \quad (15)$$

$$W_{ij}^k(k) = W_{ij}^k(k-1) + \Delta W_{ij}^k(k-1) \dots\dots(16)$$

ここで、 ϵ :学習率、 α :慣性項、 β :振動項であり、本論文では試行錯誤の結果、表1に示す値を設定した。

〈4・2〉 NNによる試験装置のモデル化⁽⁷⁾⁽⁸⁾ NCを用いた制御時のサンプリング周期は入出力処理およびグラフィック処理のため、約1〜2秒の時間が予想される。一方、制御対象の時定数は第3章で述べたように0.2秒以下の値である。従って、制御対象の入出力関係は時間遅れのない静的関係式でほぼ近似できることが予想される。そこで、まずこの入出力関係を、計算が容易な回帰式を用いて近似する。電動機の回転数がそれぞれ、578 rpm (10 km/h 走行)、1,157 rpm

(20 km/h 走行)、1,736 rpm (30 km/h 走行)、2,314 rpm (40 km/h 走行)、2,894 rpm (50 km/h 走行)、3,472 rpm (60 km/h 走行) におけるトルクの制御入力と出力の関係を図8に示す。同図において、 $L=1$ は電動機の回転数が1,736 rpm 以上、 $L=2$ は電動機の回転数がそれ以下の場合を示している。これらのデータに適合した回帰式として次式のような二次回帰式が求められた。これを図8において $L=3$ で示す。

$$y_r = 0.00242u^2 + 1.17u + 1.98 \dots\dots(17)$$

y_r : 出力 推定値(Nm), u : 制 御 入 力 (Nm), 寄与率: 0.996

次に、(17)式で近似しきれない残差をNN(2)を用いて補正する。この場合、制御対象の入出力変化の代表的な時間推移を近似するために、図5に示したデータを繰り返し用いて学習を行う。NN(2)は図9に示す3層の階層構造とし、入力層は10ユニットとし、同図の p, q はそれぞれ $p=4, q=4$ 、また中間層は10ユニットと設定した。これらの値はEV試験装置のおおざっぱな構造を考慮して、試行錯誤を行って得られた結果である。学習はバックプロパゲーション法を用

表 1 NN(1)学習パラメータ
Table 1. Learning parameters of NN(1).

学習率 (ϵ)	0.001~0.05
慣性項 (α)	0.9
振動項 (β)	-0.1

図 8 入出力データ
Fig. 8. Data of input and output.

表 2 NN(2)学習パラメータ
Table 2. Learning parameters of NN(2).

学習率 (ϵ)	0.001
慣性項 (α)	0.9
振動項 (β)	-0.1

図 9 NN(2)の構造
Fig. 9. Structure of NN(2).

(a) 初期, 学習回数(回): 0~134

(b) 終期, 学習回数(回): 181, 104~181, 242

図 10 NN(2)の学習結果
Fig. 10. Learning results by NN(2).

い、本論文で用いた学習用パラメータは表2に示している。また、ユニットの出力関数は(3)、(4)式を用い、ダイナミックゲイン $g=10$ とした。NN(2)の学習結果を図10(a)、(b)に示す。また、モデルの推定誤差を回帰式のみを用いる場合とNN(2)も併せて用いる場合を比較して図11に示す。図10(a)、(b)より、学習が進むにつれてモデルの推定誤差が減

図 11 回帰式と NN(2) による推定誤差
Fig.11. Estimation error by regression method and NN(2).

少していることがわかる。(b)図より、トルクの最大値が約17 Nmに対し、推定誤差が0.5 Nmの範囲内でモデルが近似されており、更に図11よりNN(2)の補正効果も表れている。特に、同図では出力の突変部の補正効果が顕著であることがわかる。

〈4・3〉 シミュレーションによる NC の学習

図12(a)、(b)は前節で構築したモデルを制御対象とみなし、コントローラを学習した場合のシミュレーション結果を示している。ただし、(1)式および(6)式のスケール調整定数 C_1, C_2 はいずれも0.1とした。またサンプリング周期は $T=1$ sとした。(a)図は学習の初期、(b)図は学習終了時の結果を示している。誤差は学習が進むにつれて減少していることがわかる。また、この学習過程におけるNN(1)の出力、すなわち、PID各ゲインの変化を図13(a)、(b)に示す。各ゲインとも学習の進行につれて、望ましい値に漸近している様子がうかがえる。この学習によって得られた最終のPID各ゲインは比例ゲイン $K_p=0$ 、積分ゲイン $K_i=0.67$ 、微分ゲイン $K_d=0$ であった。この K_i の値は、実機の試験装置において試行錯誤によ

図 12 NN(1)のモデルによる学習結果
Fig. 12. Training results of NN(1) by model.

図 13 NN(1)のモデルによる学習(PID ゲイン)
Fig. 13. Training results of NN(1) by model (PID gains).

り得られた $K_I=0.7$ にほぼ等しい値となっている⁽⁹⁾。

5. NCの実機への適用と考察

前章のシミュレーションによる学習の結果得られたNN(1)の重みをNCの重みの初期値として、実験装置においてオンライン学習を行う。ただし、オンライ

ン学習においては、図6のモデル部は出力の制御入力に対する勾配を推定するために、EV試験装置から切り離さないでオンライン学習を行っている。なお、モデルを修正するためのNN(2)は制御演算時間を短縮するため、学習を行わず固定して利用した。図14はこの学習の状況を示している。同図からは、学習によ

図 14 NN(1)の学習 (初期重み=モデル学習重み)

Fig. 14. Training results of NN(1) (initial weights=training results by model).

図 15 NN(1)の学習 (初期重み=乱数値)

Fig. 15. Training results of NN(1) (initial weights=random values).

図 16 NN(1)の学習 (PID ゲイン) (初期重み=乱数値)

Fig. 16. Training results of NN(1) (PID gains) (initial weights=random values).

る誤差の減少がほとんど認められない。このことはモデルを制御対象とみなしたシミュレーションによって、得られたPIDゲインが実機に対しても適正であることを意味している。

従って、オフライン学習によるNCの有効性が実機に対して示されたが、オンライン学習を行うことが実際には望ましいと思われる。そこで、以下ではこのオンライン学習による制御結果について考察する。

図15(a), (b)はオンライン学習による制御の結果を示しており、学習が進むにつれて誤差が減少していることがわかる。また、図16(a), (b)はこの間のPIDゲインの変化を示しており、PDゲインはほぼゼロ、Iゲインは適正な値に漸近している様子がわかる。この結果得られたゲインは $K_P=0.03$, $K_I=0.64$, $K_D=0$ であり、前章のシミュレーションおよび試行錯誤により得られた値にほぼ等しくなっている。

これらの結果から、本論文で用いたPID型NCは実機においても、ゲインのセルフチューニングおよび制御性能の改善に有効であることがわかる。

6. ま と め

従来のPID制御にニューラルネットワークを付加したニューロコントロールを、電動機の実機トルク制御に適用し、以下のような有効性を確認した。

(1) 制御対象のモデルの同定において、ニューラルネットワークは、非線形性や不確定な要素を含む系を同定することができる。

(2) セルフチューニングPID制御系が、NNによって適応的に構成可能である。

(3) 実機による実験においても、NNの学習機能が十分に発揮され、PIDゲインのチューニング機能を有している。

本論文では、走行パターンとして代表的な10モードパターンを考察したが、より複雑な走行パターンに関してもニューロコントローラが有効な制御手法であるか否かについては今後考察する予定である。

本研究は、四国電力(株)からの委託研究の一環として実施しており、関係各位の御指導に謝意を表します。(平成5年2月26日受付)

文 献

- (1) S. Matsumura, et al.: "Self-Tuning PID-Type Neuro-controller for Load Torque Control in Electric Vehicle Testing System", Progress in Neural Networks (掲載予定)Ablex Publishing Comp.

- (2) 大松:「ニューラルネットワークによる適応制御」, 電学誌, 112, 101 (平4-7)
- (3) R. W. Swiniaski: "Novel Neural Network Based Self-Tuning PID Controller Which Uses Pattern Recognition Technique", Proc. American Control Conference, San Diego, p. 3023 (1989)
- (4) 松村, 他:「PID型ニューロコントローラによるEV試験装置のトルク制御」, 電気学会システム・制御研究, SC-93-1, 1 (平5)
- (5) 樋口:自動車工学(昭62)朝倉書店
- (6) 大松:「ニューロコントロールと適応制御」, システム/制御/情報, 36, 769 (平4-12)
- (7) 船橋:「ニューラルネットワークのcapabilityについて」, 信学技報, MBE 88-52, 127 (昭63)
- (8) W. Thomas Miller, III, Richard S. Sutton & J. Werbos: Neural Networks for Control (1990) MIT press
- (9) S. Matsumura, et al.: "Neural Networks for Torque Control in Electric Vehicle", Neural Information Processing, Proc. ISKIT '92, p. 227 (1992)

松 村 茂 憲 (正員)

昭和23年9月6日生。47年京都大学工学部電気工学科卒業。同年四国電力(株)入社。現在、(株)四国総合研究所および徳島大学大学院工学研究科博士後期課程において、電気自動車に関する技術の研究に従事。

大 松 繁 (正員)

昭和21年12月16日生。49年大阪府立大学大学院工学研究科博士課程修了。同年徳島大学工学部情報工学科助手、63年同知能情報工学科教授となり、現在に至る。工学博士。適応制御、分布定数系の推定と制御、ニューラルネットなどの研究に従事。平成3年電気学会論文賞受賞。計測自動制御学会, SIAM, IEEE 会員。

樋 笠 博 正 (正員)

昭和6年1月8日生。26年旧制新居浜工業専門学校卒業。同年四国電力(株)入社。63年(株)四国総合研究所負荷平準化技術研究室長。第13, 30回オーム技術賞。情報処理学会会員。