

北大工 〇重松 洋一 嘉数 侑昇

1. はじめに

歩行機械やマニピュレータを高速な目標軌道で正確に制御するためには、トルク計算法<sup>1)</sup>などの逆運動学モデルを用いて、トルクをフィード・フォワードに入力するのが一般的である。

しかし、歩行機械では、目標軌道を始めから与えるためには自由度が大きすぎるので、現在の軌道がある目的関数を最小にするような軌道に漸次、近づく最適制御を行なう方がよいと考える。従って、入力トルクに対する実際の軌道を生成するために、順運動学モデルが必要になる。ここで順運動学モデルとは、時刻  $t=0$ での初期状態  $X=(q, \dot{q})$  と  $t \geq 0$ での関節トルク  $\tau(t)$  を入力したときに、 $t \geq 0$ での状態  $X(t)$  を求めるためのモデルである。 $q, \dot{q}$  は各々、関節角ベクトル、関節角速度ベクトルである。

リンク機構の順運動学モデルの一つとしてRumelhart型ニューラルネットを用いたものが提案されている<sup>2)</sup>。しかし、そこでは、重み変化巾を小さい正定数としているので、学習回数が多くなる問題がある。

ここでは、学習回数を低減させる一方法として、一次元探索を適用する。

2. ニューラルネットを用いた順運動学モデル

順運動学モデルを、図1に示すRumelhart型ネットワークで構築する<sup>2)</sup>。ネットワークは単方向の三層から構成され、第  $i$  層の  $m$  番目の細胞は三つ組  $(X_m^i, Y_m^i, th_m^i)$  で表わされる。ここで、 $X_m^i, Y_m^i, th_m^i$  は各々、入力、出力、しきい値である。

第  $i$  層 ( $i=2$  または  $3$ ) の  $m$  番目の細胞の  $X_m^i, Y_m^i$  は次式で与えられる。

$$X_m^i = \sum_k W_{k,m}^{i-1,i} Y_k^{i-1} - th_m^i \quad (1)$$

$$Y_m^i = f(X_m^i) \quad (2)$$

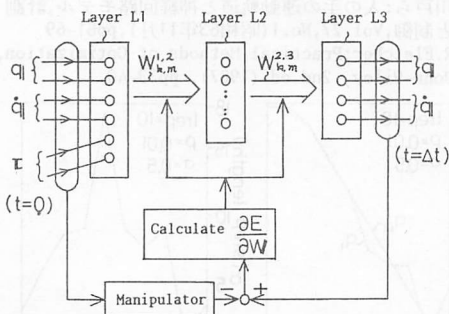


図1 ニューラルネットを用いた順運動学モデル

ここで  $f$  は次式のシグモイド関数である。

$$f(x) = \frac{1}{1 + \exp(-\alpha x)} \quad (3)$$

また、 $W_{k,m}^{i-1,i}$  は第  $i-1$  層の  $k$  番目の細胞と第  $i$  層の  $m$  番目の細胞間の重みである。

第1層の  $m$  番目の細胞の  $X_m^1$  は外から与え、 $Y_m^1$  は次式で与える。

$$Y_m^1 = X_m^1 - th_m^1 \quad (4)$$

図1において、 $\{X_m^1\}$  は  $t=0$ での状態  $X(0)$  と関節トルク  $\tau(0)$  であり、 $\{Y_m^3\}$  は  $t = \Delta t$ での状態  $X(\Delta t)$  である。式(2)から、 $Y_m^3$  は  $[0, 1]$ 内の値であるので、 $[0, 1]$ 外の状態  $X$  を表わすために、 $Y_m^3$  に定数をかける。

3. バックプロパゲーションへの一次元探索の適用

重み  $W_{k,m}^{i-1,i}$  の学習法であるバックプロパゲーションでは、次の誤差関数  $E$  を、最急降下法を用いて最小化する。

$$E = \sum_d |Y^3 - Y_d^3|^2 \quad (5)$$

ここで  $\sum_d$  は学習パターンについての総和、 $Y^3$  は入力  $\{X_m^1\}$  に対するネットワークの出力、 $Y_d^3$  は同じ入力  $\{X_m^1\}$  に対する教師信号である(図1)。

バックプロパゲーションにおける重み更新式は次式で与えられる。

$$\Delta W = -\epsilon \frac{\partial E}{\partial W_n} - \alpha \epsilon \frac{\partial E}{\partial W_{n-1}} \quad (6)$$

ここで右辺第一項は現在の勾配、右辺第二項はひとつ前の勾配である。また、 $\epsilon, \alpha$  は各々、小さい正定数である。

バックプロパゲーションを用いてネットワーク内に順運動学モデルを構築するためには、多くの学習回数が必要である。これは、収束次数の小さい最急降下法に更に、小さい正定数  $\epsilon, \alpha$  をかけているので、一回の学習での重み変化量が小さすぎるからであると考えられる。

そこで、ここでは、収束を加速するために、最急降下方向に一次元探索する方法を提案する。

一次元探索には種々の方法があるが、ここでは、極小点が存在する許容区間を確実に探索する Wolfe-Powell の方法<sup>3)</sup>を用いる。Wolfe-Powell の方法では、次の二条件を満たす探索巾  $\alpha$  を、探索区間の囲い込みと分割を併用して求める。

$$f(\alpha) < f(0) + \alpha \rho f'(0) \quad (7)$$

$$|f'(\alpha)| \leq -\sigma f'(0) \quad (8)$$

ここで  $f(\alpha)$  は次式のように誤差関数  $E$  の最急降下方向への一次元関数である。

$$f(\alpha) = E(W + \alpha \Delta W) \quad (9)$$

また、 $\rho$  は大きすぎる  $\alpha$  部を探さないために用いる  $\rho$ -line の傾き倍率、 $\sigma$  は許容区間での傾き倍率である(図2)。

囲い込みと分割のフローを各々、図3, 4に示す。




図2 Wolfe-Powellの一次元探索

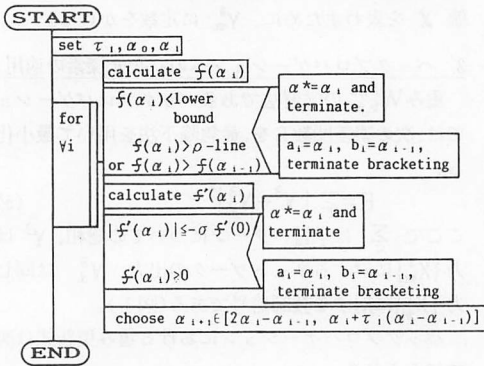


図3 囲い込みのゼネラル・フロー

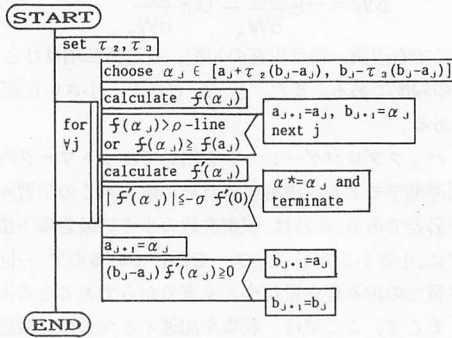


図4 分割のゼネラル・フロー




図5 水平二自由度マニピュレータ




図6 最急降下法の適用




図7 一次元探索の適用




図8 探索巾の変化

#### 4. 実験と考察

一次元探索の効果を調べるために、最急降下法だけのバックプロパゲーションと一次元探索を用いたものとを比較実験した。

実験対象は図5の水平二自由度マニピュレータである。

入力は $C^3$ の軌道 $q(t)$ と対応する $\tau(t)$ を0~1秒間で10等分したときの離散値とする。ここで $q(t)$ は $q(0)=\dot{q}(0)=\ddot{q}(0)=0, q(1)=1, t \in [0, 1/10]$ と $t \in [9/10, 1]$ において各々、 $t$ の三次式を用いて加減速し、 $t \in [1/10, 9/10]$ において $t$ の一次式を用いて等速にする。出力は各入力0.05秒後の状態 $X$ とする。

学習は各 $(X, \tau)$ 入力毎に重みを更新する個別学習とする。一連の11個の入力組を1~10回、繰り返し入力したときの学習結果を図6, 7に示す。図より、一次元探索を用いた方が最急降下法を用いたものより目標軌道に近づいていることがわかる。

また、一次元探索の探索巾は、一連の入力を10回繰り返した後も小さくならない(図8)。これは、等速軌道で学習中にはネットワークの軌道が目標軌道に近づいても、加減速軌道で学習すると、再び重みを大きく更新してしまうので、等速部の軌道が劣化するからである。従って、加減速部と等速部を含めた一連の入力の後に重みを更新するセット学習を用いれば、劣化を防げ、探索巾も減少させられると考える。

#### 5. おわりに

ここではバックプロパゲーションへの一次元探索の適用を提案した。比較実験により、一次元探索を用いた方が最急降下法を用いたものよりも学習回数が少なくても学習することを示した。セット学習と文献2に示すような最急降下法だけを用いた実験の追試に関しては、今後、検討する予定である。

#### 参考文献

- 1) J.Y.S.Luh, et al.: On-line Computational Scheme for Mechanical Manipulators, in Robot Motion: Planning and Control (M.Brady, et al. eds.), The MIT Press (1982), pp89-106
- 2) 川戸ら: 人の手の運動軌道と神経回路モデル, 計測と制御, Vol. 27, No. 1 (昭和63年11月), pp61-69
- 3) R.Fletcher: Practical Methods of Optimization, John-Wiley, 2nd.ed. (1987), pp33-40