

神経回路による逆問題の反復解法システム[†]

大山英明*・館 瞳**

An Iterative System for Solving Inverse Problems by Using Neural Networks

Eime OYAMA* and Susumu TACHI**

In order to solve the inverse problems for the system with unknown characteristics, many researchers have used a method that uses an inverse model of the target system, which is acquired by learning. The direct inverse modeling, the forward and inverse modeling and the goal directed model inversion were proposed for the acquisition. However, precise inverse models for some kind of systems cannot be obtained by these method. Furthermore, a limited scale neural networks system has only limited precision. Errors still remains in the output of the inverse model using the neural networks system. The use of the inverse model is not always a good method for solving inverse problems.

Another way to solve the inverse problem is by an iterative method. We proposed a generalized inverse model with output feedback as a model of a human nervous system solving inverse kinematics problem of a human arm. The system acquires the inverse model of the linearized model of the human arm by using neural networks and uses the inverse model as an output feedback system. The system approximates the iterative improvement of Newton's method. We call the system Output Feedback Inverse Model. However, the precision of solutions provided by the system is low.

In order to make the precision high, we improve the system and propose a new configuration of the iterative system using neural networks. We call the improved system Modified Output Feedback Inverse Model. By using a random search technique for the initial value, the proposed system provides more precise solutions than the conventional methods.

The performance of the proposed method are shown by numerical simulations.

Key Words: neural networks, inverse problems, Newton's method, modified output feedback inverse model

1. まえがき

対象システムの目標出力を与えたとき、それを実現するシステムへの入力を求める問題は逆問題と呼ばれている。対象システムの特性が未知であるとき、対象システムの入出力を観測し、神経回路などの学習要素によって、逆問題解法システムを獲得することを考える。

従来、神経回路などの学習要素により対象システムの

逆モデルを獲得して、その出力を逆問題の解とする解法システムが研究されてきた^{1)~3)}。しかしながら、逆モデルの獲得は多くの問題を抱えている⁴⁾。代表的な逆モデル獲得法である直接逆モデリングは、非線形の多対一対応システムの正確な逆モデルを得ることができない¹⁾。直接逆モデリングの弱点を解決するために、Jordanらが提案した順逆モデリング¹⁾や川人らのフィードバック誤差学習²⁾、Colombanoらの目標指向型モデル反転(Goal Directed Model Inversion)³⁾は、学習要素の初期状態によっては、逆モデルを獲得できないという弱点がある⁴⁾。非線形システムの逆問題を解くために、逆モデルを利用する解法システムは、対象システムによっては有効ではない。また、通常、学習要素の精度は有限であり、学習要素のモデル化誤差に起因する誤差がシステムの出力に残る。

† IJCNN'93 NAGOYA で発表(1993.10)

* 機械技術研究所 つくば市並木 1-2

** 東京大学工学部 東京都文京区本郷 7-3-1

* Mechanical Engineering Laboratory, Tsukuba Science City

** Faculty of Engineering, University of Tokyo, Bunkyo-ku, Tokyo

(Received April 5, 1994)

(Revised July 26, 1994)

逆問題の解法には、逆モデルを利用する手法のほかに、システムの線形近似に基づく反復解法がある。著者らは、人間の上肢逆運動学問題の解法システムとして、近似的に広義のニュートン法を実現する出力フィードバック型逆モデルを提案した^{5),6)}。しかしながら、この手法には、高精度の解を得られないという問題点があった。本論文では、これを改良し、高精度の解を得ることのできる学習型の反復解法システムを提案する。この解法システムは、対象システムの入出力の微小変化の関係が線形とみなせることに着目し、その逆モデルを直接逆モデリングによって学習する。学習した逆モデルを利用して、出力誤差を入力の修正量に変換する出力誤差フィードバック回路を構成し、ニュートン法と類似した反復改良演算を行う。初期値のランダム探索と組み合せることによって、連続な非線形システムの逆問題において、高精度の解を得ることが可能である。

多項式関数の逆問題と冗長マニピュレータアームの逆運動学問題を例にとり、学習によって解法システムを獲得するシミュレーション実験を行い、提案した手法の評価を行う。

2. 修正出力フィードバック型逆モデル

m 次元入力ベクトルを x , n 次元出力ベクトルを y として、入出力関係が

$$y = f(x) \quad (1)$$

となるシステムが存在するものとする。このシステムに対して、入力 x を自由に与えることができ、そのときの出力 y を観測できるものとする。出力 y の目標値 y_d が与えられたとき、

$$y_d = f(x_d) \quad (2)$$

を実現する入力 x の値 x_d を計算する逆問題について、対象システム $f(x)$ の特性が未知であるとき、その入出力を観測し、学習要素を用いて、逆問題解法システムを獲得することを考える。

学習要素 $\Phi(t)$ は任意の連続関数を近似できるものとする。理想的な学習要素では、入力が t であるとき、教師信号 s_i が与えられた場合、最終的に、

$$\Phi(t) = E(s_i) \quad (3)$$

となるように、学習が行われるものとする。 $E(s)$ はベクトル s の平均値を示す。現在、提案されている神経回路モデルのほとんどはこの性質を近似的に満たしている。そのような学習要素としては、たとえば、バックプロパゲーション学習を行う多層神経回路⁷⁾がある。

2.1 修正出力フィードバック型逆モデル

1章で述べたように、非線形システムの逆問題を解くために逆モデルを用いる手法には問題がある。逆問題を

解く手法として、非線形方程式の線形近似に基づく反復解法があり、たとえば、次式のような広義のニュートン法がある。

$$\begin{aligned} x(k+1) &= x(k) \\ &\quad + A^*(x(k))(y_d - f(x(k))) \\ A(x) &= \frac{\partial f(x)}{\partial x} \end{aligned} \quad (4)$$

k は反復回数であり、 $A(x)$ を $f(x)$ のヤコビ行列とすると、 $A^*(x)$ は $A(x)$ の適当な一般化逆行列である。初期値のランダム探索と反復演算を繰り返すことにより、十分長い計算時間があれば、連続な非線形システムの逆問題を高精度に解くことができる。

システムの特性が未知である場合、この反復演算を行うためには、数値微分によってヤコビ行列を計算し、一般化逆行列を求め、出力誤差に乘じることにより、(4)式の更新式の右辺第2項を計算する必要がある。数値微分によってヤコビ行列を計算するためには、 m 次元ベクトル x の値を、 m 回微小変化させ、 $f(x)$ の変化を観測する必要がある。1回の反復演算あたり、少なくとも $m+1$ 回のシステムの出力 $f(x)$ の観測が必要となり、処理時間は大きくなる。

このような反復解法システムを学習要素によって構成することを考える。学習型の解法システムは、反復解法が有効な対象システムの逆問題を解くことができ、さらに、特性が未知であったり、特性が変化したりする対象システムについても、学習により対応することができる。本論文では、Fig. 1 のような解法システムを提案する。この解法システムは、

$$\begin{aligned} x(k+1) &= x(k) \\ &\quad + \Psi(x(k), y_d - f(x(k))) \\ &\quad - \Psi(x(k), 0) \end{aligned} \quad (5)$$

のような反復改良を行う。 $\Psi(x, \Delta y)$ は、

$$|\Delta y| < r_y \quad (6)$$

が成立する領域において、

$$\Phi(x, \Delta y) = A^*(x) \Delta y \quad (7)$$

を満たす学習要素 $\Phi(x, \Delta y)$ を利用して次式のように構成される出力誤差のフィードバック回路である。

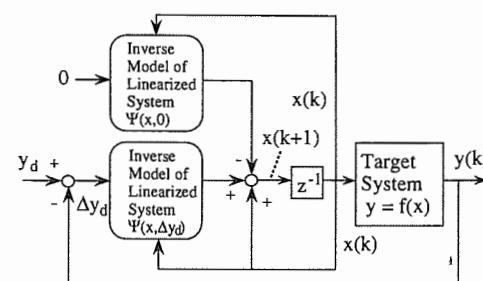


Fig. 1 Modified Output Feedback Inverse Model

$$\Psi(x, \Delta y_d) = (1/K) \Phi(x, K\Delta y_d) \doteq A^*(x) \Delta y_d \quad (8)$$

学習要素 $\Phi(x, \Delta y)$ の学習法については、次章で述べる。 K は、反復改良における出力誤差を

$$\Delta y_d(k) = y_d - f(x(k)) \quad (9)$$

とし、 $|\Delta y_d(k)|$ の最大値を r_{yd} とすると

$$|K| < r_y/r_{yd} \quad (10)$$

を満たす、適当な係数である。 (10) , (6) , (7) 式により、 (8) 式は学習要素の入力 $(x, \Delta y_d)$ の取り得る値の全域において成立する。よって、 (5) 式より、

$$x(k+1) \doteq x(k) + A^*(x)(y_d - f(x(k))) \quad (11)$$

が成立し、 (4) 式の反復改良を近似的に実現できる。この反復改良システムは、1回のシステムの出力の観測によって、1回の反復改良を行うことができる。このシステムを修正出力フィードバック型逆モデルと呼んでいる。

2.2 解の収束特性

付録1に示すように、提案法の原型である出力フィードバック型逆モデルには、高精度の解を得ることが難しいという弱点があった。提案法では、Atkesonの学習制御⁸⁾の手法を応用して、 (5) 式の右辺第3項を付加している。これにより、高精度の解が得られるこれを本節では示す。

出力誤差 Δy_d が十分小さい時点において、フィードバック項 $\Psi(x, \Delta y_d)$ を Δy_d についてテイラー展開すると、

$$\begin{aligned} \Psi(x, \Delta y_d) &= (1/K) \Phi(x, K\Delta y_d) \\ &= \Psi(x, 0) + H(x) \Delta y_d + O(\Delta y_d^2) \\ &= \Phi(x, 0) + H(x) \Delta y_d + O(\Delta y_d^2) \end{aligned} \quad (12)$$

$$\begin{aligned} H(x) &= \frac{\partial \Psi(x, \Delta y)}{\partial \Delta y} \Big|_{\Delta y=0} \\ &= \frac{\partial \Phi(x, \Delta y)}{\partial \Delta y} \Big|_{\Delta y=0} \end{aligned} \quad (13)$$

を得る。 $O(t^2)$ は、それぞれの方程式において t の2次以上の高次項の総和を表わすものとする。 (12) 式より、 (5) 式は、

$$x(k+1) = x(k) + H(x(k)) \Delta y_d(k) + O(\Delta y_d(k)^2) \quad (14)$$

と展開でき、出力誤差の変化は

$$\begin{aligned} \Delta y_d(k+1) &= (I - A(x(k))H(x(k))) \Delta y_d(k) \\ &\quad + O(\Delta y_d(k)^2) \end{aligned} \quad (15)$$

と展開できる。 (15) 式において、出力誤差 $\Delta y_d(k)$ が十分小さいとき、右辺第2項は2次の微小量となり、右辺第1項が支配的になる。 $|\Delta y_d(0)|$ が十分小さいとき、非線形方程式の逐次解法の性質から、

$$0 < |I - A(x)H(x)| < 1 \quad (16)$$

が成立すれば、

$$|\Delta y_d(k)| \leq \lambda^k |\Delta y_d(0)| \quad (17)$$

$$|I - A(x)H(x)| \leq \lambda < 1 \quad (18)$$

を満たす実数 λ が存在する。ただし、行列のノルムとしてベクトルノルムに従属するノルムを利用するものとする。 (16) 式が成立すれば、 (17) 式より、

$$\Delta y_d(k) \rightarrow 0 \quad (k \rightarrow \infty) \quad (19)$$

が成立する。学習が十分進んだ状態では、 (7) 式と (13) 式より、

$$H(x) \doteq A^*(x) \quad (20)$$

である。よって、

$$I - A(x)H(x) \doteq I - A(x)A^*(x) = 0 \quad (21)$$

であり、通常、 (16) 式が成立する。以上のように、提案法では、 $x(0)$ が十分真の解に近ければ、反復改良によって、高精度の解を得ることができる。 $\Phi(x, \Delta y)$ が高精度になるにつれ、 λ は 0 により近い値をとることができ、高速な誤差の減少が期待できる。

2.3 局所最小解の判別条件

提案法では、理想的に学習が行われたとしても、解の計算は局所的な情報に基づいて行われるため、最終的に真の解に到達できるとは限らない。解の推定値が局所最小解に収束したり、解の定義域外にはずれたりする場合がある。真の解に到達させるためには、乱数などにより、初期値を変えて再び反復計算を行う機構があれば良い。局所解に達したことを判断する条件は、 ρ, μ を十分小さな定数として、次式が成立することとする。

$$|y_d - y(k)| > \rho \quad (22)$$

$$|y(k+1) - y(k)| \leq \mu |y_d - y(k)| \quad (23)$$

3. 学習要素の学習法

学習要素の学習法には、大きく分けて、オフライン学習法とオンライン学習法があり、オフライン学習には、2種類の方法がある。オフライン学習の第1の手法は、次式のように、 (7) 式の右辺を直接計算し、学習要素 $\Phi(x, \Delta y)$ の教師信号 $\Phi'(x, \Delta y)$ とする手法である。

$$\Phi'(x, \Delta y) = A^*(x) \Delta y \quad (24)$$

これは、数値微分によって、ヤコビ行列 $A(x)$ を推定し、その一般化逆行列 $A^*(x)$ を計算し、 Δy に乘じることによって計算できる。この場合、ヤコビ行列の計算のために特別に対象システムを動作させる必要があり、計算も複雑であるが、学習要素のための教師データを一括して生成し、一括して学習を行う場合には便利である。

オフライン学習の第2の手法は、対象システムの入力の微小変化 Δx とそれに対応する出力の微小変化 Δy に着目する。両者には

$$\Delta y = f(x + \Delta x) - f(x) \doteq A(x) \Delta x \quad (25)$$

のような線形の関係がある。十分小さいパラメータ r_x について、

$$|\Delta x| < r_x \quad (26)$$

が成り立つとき、教師信号 $\Phi'(x, \Delta y)$ を、

$$\Phi'(x, \Delta y) = \Delta x \quad (27)$$

とする。Fig. 2 に学習の概念図を示す。付録 1 に示すように、学習によって、

$$\Phi(x, \Delta y) = A^*(x)\Delta y + (I - A^*(x)A(x))v \quad (28)$$

が成立する。上式の右辺は(25)式の逆モデルである。

$A^*(x)$ は $A(x)$ の疑似逆行列(Moore-Penrose の一般化逆行列)であり、 v は適切な m 次元ベクトルである。

すべての x について、

$$E(\Delta x) = 0 \quad (29)$$

と仮定すると、付録 1 に示すように、

$$\Phi(x, \Delta y) = E(\Delta x) = A^*(x)\Delta y \quad (30)$$

を実現できる。

解法システムが十分な性能をもつためには、学習要素の入力 $(x, \Delta y_d)$ が取り得る値の全域にわたって、学習を行う必要がある。 x の定義域の全域において、対象システムの入力変化 Δx が、(26)式を満たす領域の全域に広がって分布し、かつ $A(x)$ が正則であるとする。(25)式より、 Δy は、(6)式の r_y が適切であれば、(6)式を満たす領域の全域に広がって分布することになり、入力 $(x, \Delta y_d)$ の取り得る値の全域にわたる学習が可能となる。

続いて、オンライン学習について述べる。オフライン学習と同様、(26)式の条件の基に、(27)式を用いて、オンライン学習が可能である。反復改良演算の過程においては、システムへの入力 x の変化は、

$$\Delta x = \Psi(x, \Delta y_d) - \Psi(x, 0) \quad (31)$$

であり、出力 y の変化は

$$\Delta y = A(x)H(x)\Delta y_d \quad (32)$$

となる。 $A(x)H(x)$ がフルランクならば、 $\Delta y = 0$ の場合、 $\Delta x = 0$ であり、

$$\Phi(x, 0) = 0 \quad (33)$$

を得る。(28)式の右辺第2項は近似的に 0 になり、オンライン学習においても、(30)式が成立する。

(32)式より、 $A(x)H(x)$ がフルランクで、出力誤差 Δy_d が $\Delta y_d = 0$ を中心とする空間の全方向に分布し、(6)式の r_y の値が適切であれば、 Δy は(6)式を満たす

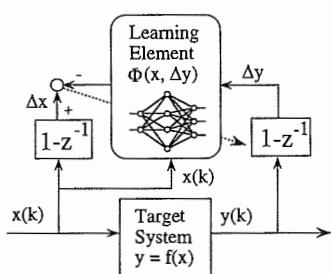


Fig. 2 Teaching signal for learning element

領域の全域に広がって分布することになり、入力の取り得る値の全域にわたる学習が可能となる。

なお、オンライン学習において、逆問題の求解計算時には、 $|\Delta y|$ が非常に小さな領域に集中しがちであり、ほかの領域の学習に非常に大きな時間がかかるという問題がある。適当な係数 β を利用し、

$$\Phi'(x, \beta\Delta y) = \beta\Delta x \quad (34)$$

とすることによって、この問題を解決できる。 β としては、適当な係数 γ と適当な乱数 ω を利用し、

$$\beta = \gamma\omega / |\Delta x| \quad (35)$$

とすれば良い。

4. シミュレーション

提案した解法システムの性能を評価するために、多項式関数の逆問題と冗長マニピュレータームの逆運動学問題の解法システムを提案法によって構成するシミュレーション実験を行う。本稿で提案した改良型システムを MOFIM(Modified Output Feedback Inverse Model)と略すことにする。比較のために、付録 1 で述べる出力フィードバック型逆モデルによる解法システム、(5)式のニュートン法による解法システム、順逆モデルによる逆モデルを用意し、それぞれ OFIM(Output Feedback Inverse Model), NM(Newton's Method)と FIM(Forward and Inverse Modeling)と略することにする。

OFIM, MOFIM, NM の解の計算時において、反復改良の初期値 $x(0)$ は一様乱数によって与える。解の推定値 $x(k)$ が定義域を外れる場合や、局所最小解の判別式(23)が成立した場合には、初期値を変更して再計算を行う。(23)式のパラメータ μ は 0.01 とする。反復の停止条件は、逆問題を解く試行において、目標出力が許容誤差 ρ 以下で達成されるか、反復回数の合計が 1000 回を越えることとする。反復回数の合計が 1000 回を越えた試行は失敗とみなす。

シミュレーションで用いる学習要素は 4 層の神経回路であり、中間層を構成する第 2 層と第 3 層に、シグモイド関数 ($y = 1/2 \tanh(x)$) で記述される入出力特性をもつ非線形の神経素子を配置し、入力層と出力層は線形神経素子とする。学習法としては、バックプロパゲーション法を用いる。 i 回目の学習時における神経回路の出力を $\Phi^{(i)}$ 、教師信号を $\Phi'^{(i)}$ 、誤差評価関数を

$$S^{(i)} = |\Phi'^{(i)} - \Phi^{(i)}|^2 \quad (36)$$

とする。神経回路の j 番目の結線の結合加重を w_j とする。 i 回目の学習時における w_j の修正量 $\Delta w_j^{(i)}$ は、学習率を η 、慣性率を α として、バックプロパゲーション学習により、次式のように計算する。

$$\Delta w_j^{(i)} = -\eta \frac{\partial S^{(i)}}{\partial w_j} + \alpha \Delta w_j^{(i-1)} \quad (37)$$

結合荷重 w_j の初期値は、 $(-0.5, 0.5)$ に一様に分布する乱数によって与える。

4.1 多項式関数の逆関数システム

次式で定義される多項式関数について、逆問題解法システムをオフライン学習によって構成するシミュレーションを行う。

$$y=f(x)=\frac{1}{3}x^3-x \quad (38)$$

入力 x の定義域は $[-3, 3]$ であり、出力 y の値域は $[-6, 6]$ である。この多項式関数は、

$$-\frac{2}{3} \leq y \leq \frac{2}{3} \quad (39)$$

において、一つの y に対応する x の値が複数存在する多対一対応システムであり、従来法による、正確な逆モデルの学習は難しい。

FIM における逆モデルの各層を構成する神経素子の個数は入力層から順に、1 個、8 個、8 個、1 個である。OFIM, MOFIM においては、2 個、8 個、8 個、1 個である。

OFIM, MOFIM について、オフライン学習のシミュレーションを行う。MOFIM において、(8)式のパラメータ K の値は、0.1 とする。OFIM, MOFIM では、一様乱数により入力 x の値を発生させ、標準偏差 $\sigma=0.05$ の正規乱数によって、 x の微小変位 Δx を発生させ、出力 y の変化 Δy を観測し、(26)式に従ってオフライン学習を行った。FIM に関しては、一様乱数によって出力目標値 y_d の値を発生させて、それを逆モデルに入力し、学習を行った。FIM の教師信号の計算においては、学習した順モデルではなく、正確な順モデルを用いて計算を行った。バックプロパゲーション学習のパラメータは、全ての解法システムについて、学習率 $\eta=0.0001$ 、慣性率 $\alpha=0.5$ とした。学習回数は、全ての解法について、10 万回である。

性能の評価においては、出力 y の値域 $[-6, 6]$ を 1000 分割し、それぞれの y の値を目標値 y_d とし、各解法システムに与え、解を計算させ、出力の RMS(Root Mean Square)誤差、出力誤差が目標値以下になる確率、必要な反復回数の平均値などを調べる。出力の RMS 誤差に関して、OFIM, MOFIM においては、一つの目標出力に対する試行の中で最も出力誤差が小さくなつたときの値をその試行における出力誤差として計算を行う。出力誤差の目標値 ρ は 0.0001 とする。

Table 1 に、FIM, OFIM, MOFIM, NM について、シミュレーションの結果を示す。FIM の結果は 100 個の

Table 1 Results of offline learning

Method	RMS Error of Output	Successful Trials (%)	Number of Iterations
FIM	2.1×10^0	0.0	—
OFIM	4.3×10^{-2}	17.3	56.5
MOFIM	6.4×10^{-5}	100.0	14.1
NM	6.5×10^{-5}	100.0	17.3

学習要素の初期状態より学習を行った中で、最も精度が高かったものである。FIM は不正確であり、OFIM は FIM に比べれば精度の良い解を得ることができているが、十分ではない。MOFIM では正確な解を得ることが可能である。本節のシミュレーション結果は、従来法が不得意とする逆問題を提案法が解くことができることを示している。

4.2 冗長アームの逆運動学解法システム

前節において、MOFIM の有効性が示されたが、本節では、入力の数が出力の数よりも多い冗長システムについて、MOFIM をより詳細に評価するためのシミュレーションを行う。2 次元平面上で動く、3 自由度アームの関節角 $\theta=(\theta_1, \theta_2, \theta_3)$ とそのアーム先端位置 $z=(x, y)$ の関係は

$$\begin{aligned} x &= x_0 + L_1 \cos(\theta_1) + L_2 \cos(\theta_1 + \theta_2) \\ &\quad + L_3 \cos(\theta_1 + \theta_2 + \theta_3) \\ y &= y_0 + L_1 \sin(\theta_1) + L_2 \sin(\theta_1 + \theta_2) \\ &\quad + L_3 \sin(\theta_1 + \theta_2 + \theta_3) \end{aligned} \quad (40)$$

である。 θ_1 の可動範囲は $[-30^\circ, 120^\circ]$ 、 θ_2 の可動範囲は $[0^\circ, 120^\circ]$ 、 θ_3 の可動範囲は $[-60^\circ, 60^\circ]$ とする。アームの寸法は $L_1=0.30$ m, $L_2=0.25$ m, $L_3=0.15$ m とする。先端位置 $z_d=(x_d, y_d)$ を実現する $\theta=(\theta_1, \theta_2, \theta_3)$ を求める逆運動学問題の解法システムを学習によって獲得するシミュレーションを行う。MOFIM の神経回路は、入力層から順に、5 個、15 個、15 個、3 個の神経素子によって構成されている。

4.2.1 オフライン学習

4.1 節と同様に、一様乱数により関節角ベクトル θ の値を発生させ、各関節角に標準偏差 σ (rad) の正規乱数による微小変位を加えて、微小変位 $\Delta \theta$ を発生させ、手先位置 z の変化 Δz を観測し、(26)式に従って学習を行う。

MOFIM の(8)式のパラメータ K と関節角に加える正規乱数の標準偏差 σ を変えて学習を行い、性能の変化を調べる。 K の値は 0.0001, 0.001, …, 1.0 と変え、 σ は 0.1 から 0.5 まで、0.05 置きに変える。

バックプロパゲーション学習のパラメータは、慣性率を $\alpha=0.5$ と固定した状態で、学習率 η を 10^{-p} ($p=0, 1, \dots, 5$) と変化させ、多くの場合において、最も性能が良かった $\eta=0.1$ を選んだ。学習回数は 100 万回である。

性能の評価においては、一様乱数によって関節角ベクトル θ を生成し、対象アームに入力して、そのときの先端位置 z を目標出力 z_d と定め、逆運動学問題を解く試行を行う。この試行を1万回行い、出力誤差が目標値 ρ (m) 以下になる確率(%)とそれに必要な平均の反復回数を調べた。Fig. 3に、MOFIMの学習結果の一例を示す。横軸は、出力誤差の目標値であり、(a)に、出力誤差が目標値以下になる確率を示し、(b)に必要な反復回数を示す。図中の(0.1, 0.25), (0.1, 0.5)などの数字の組は、(8)式のパラメータ K と関節角に加える正規乱数の標準偏差 σ の組(K, σ)に対応している。

MOFIMの性能は、 K の値の変化にはあまり敏感でなく、 $K=0.01$ から $K=0.1$ の間では、ほとんど違いがない。ただし、 $K \leq 0.001$ や $K=1.0$ の場合には、性能が劣化している。一方、 σ の変化に対しては敏感であり、たとえば、 $K=0.1$ の場合、 σ が0.25から0.2に変わると、出力誤差の目標値0.0001(m)を実現するために必要な反復回数は、5回程度増加している。 σ を決定する効率の良い手法の開発は今後の課題である。

4.2.2 オンライン学習

MOFIMについて、未学習の状態から、逆運動学問題を解く試行を行いつつ、オンライン学習を行い、その性能の向上を調べるシミュレーションを行う。

逆運動学問題を解く際においては、オンライン学習の性能評価時と同様にして、目標出力 z_d を生成し、逆運動

学問題を解く。出力の許容誤差 ρ は0.0001(m)とする。一つの目標値について、反復回数の総和が、1000回を越えると、その試行は失敗したものとみなし、つぎの目標値を生成し、試行を繰り返す。

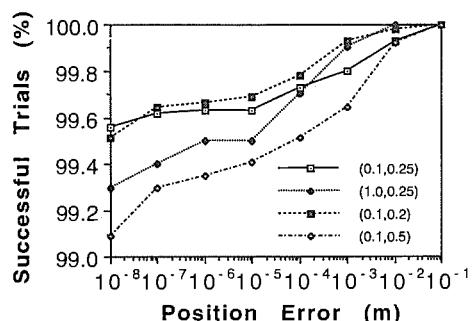
オンライン学習においては、オフライン学習で性能の良かった σ の値0.25を基準に考えて、 $|\Delta\theta|$ の上限を

$$|\Delta\theta| < r$$

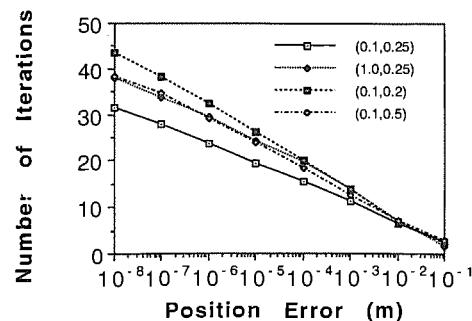
$$r = 0.25 \text{ (rad)} \times 2 = 0.5 \text{ (rad)} = 28.6^\circ \quad (41)$$

とし、オンライン学習のための、新しい学習式(34)を利用して学習を行う。更新式のパラメータ K と(34)式のパラメータ β を決定する(35)式のパラメータ γ を変化させて、性能の変化を見る。 K の値は0.0001, 0.001, …, 1.0と変え、 γ は0.1から1.0まで、0.05置きに変える。

バックプロパゲーション学習においては、学習率を0.1とし、慣性率を0.5とする。これらの値は、オフライン

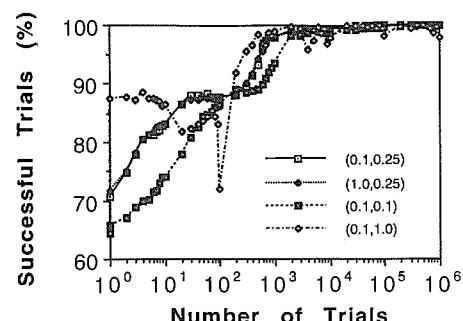


(a) Percentage of successful trials(%)

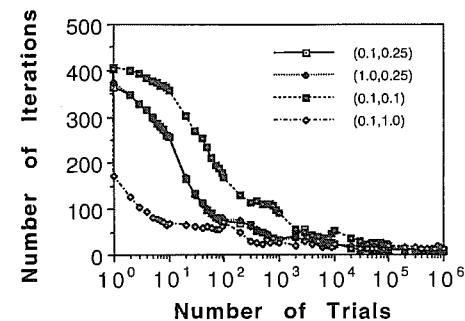


(b) Required number of iterations

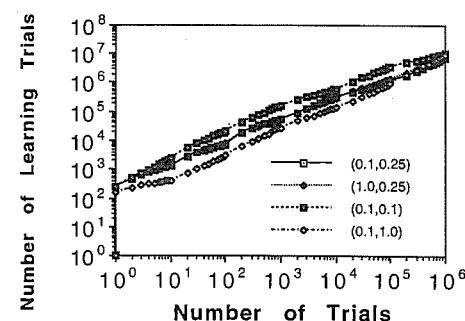
Fig. 3 Results of offline learning



(a) Percentage of successful trials(%)



(b) Required number of iterations



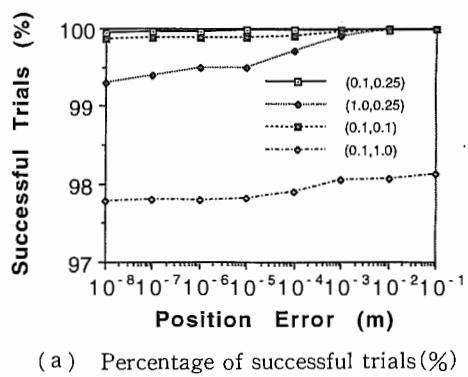
(c) Number of learning trials

Fig. 4 Change of performance by online learning

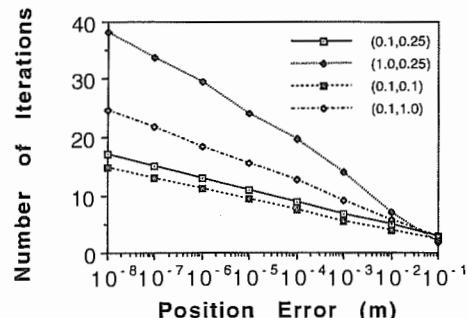
学習と同様にして決定した。

性能の評価においては、前節と同様に、学習を止めて、多数回の試行を行い、出力誤差が目標値以下になる確率(%)とそれに必要な平均の反復回数を調べる。Fig. 4に学習に伴う解法システムの性能の変化の様子を示し、Fig. 5に100万回試行を行った時点での性能を示す。Fig. 4では、性能評価のために1000回の試行を行い、Fig. 5では10000回の試行を行っている。図中の(0.1, 0.25), (0.1, 0.1)などの数字の組は、パラメータ K とパラメータ γ の組 (K, γ) に対応している。Fig. 4の(a), (b)において、出力誤差の目標値 ρ は0.0001(m)である。Fig. 4の(c)は、学習要素の学習回数の累計である。Fig. 4に示すように、オンライン学習によって、逆運動学問題を解く試行を繰り返すにつれ、解法システムの性能が向上している。

解法システムの性能は、オンライン学習の場合と同様、 K の値の変化に対して、あまり敏感でなく、 K が0.001～0.1の場合には、ほとんど違いがないため、そのうちの $K=0.1$ の場合のみを、Fig. 4, Fig. 5には示している。ただし、 K が0.1から1.0に変化することにより、 $\gamma=0.25$ の場合、出力誤差0.0001(m)を実現するために必要な反復回数は10回程度増大している。 γ の変化に対しては、性能は比較的敏感に変化する。 γ が0.25から1.0に変化することにより、前記の反復回数は、 $K=0.1$ の場合、5回程度増大している。 γ を決定する効率の良い



(a) Percentage of successful trials(%)

(b) Required number of iterations
Fig. 5 Results of online learning

手法の開発は今後の課題である。

Fig. 5に示すように、最終的にオンライン学習は、オフライン学習のときよりも性能が向上している。ただし、Fig. 4(c)に示すように、オンライン学習では、1回の試行において、数十から数百回のバックプロパゲーション学習を行っており、同じバックプロパゲーション学習の回数で比較すれば、オフライン学習が有利である。オフライン学習後にオンライン学習で仕上げを行う手法が有利と考えられる。

5. む す び

多対一対応の対象システムについて、その線形化モデルの逆モデルを直接逆モデルングによって獲得し、システム出力空間の誤差を入力の修正量に変換するフィードバック回路を形成し、反復改良演算によって、逆問題を解く方式を提案した。シミュレーションによって、その性能の評価を行い、多項式関数の逆問題や平面上の3自由度アームの逆運動学問題において、高精度の解が得られることを確認した。

反復改良によって解の計算を行うため計算時間が大きいという問題点もあるが、高精度の解を得ることができるため、ニューラル・コンピュータが実現し、高速な学習と動作が可能になれば、逆モデルを得ることが難しい対象システムの解法システムを得る有用な手法となると考えられる。

逆モデルの利用や学習係数の最適化、反復計算時における直線探索の利用などは今後の課題である。

研究を進めるにあたり、資料をお送り下さったATR人間情報通信研究所第3研究室川人光男室長、論文作成に協力して下さった機械技術研究所ロボット工学部バイオロボティクス研究室主任研究官荒井裕彦氏、実験補助員宮崎江美氏に深謝します。

参 考 文 献

- M. I. Jordan : Supervised Learning and Systems with Excess Degrees of Freedom, COINS Technical Report, 88-27, 1/41 (1988)
- M. Kawato, K. Furukawa and R. Suzuki : A Hierarchical Neural-network Model for Control and Learning of Voluntary Movement, Biol. Cybern., 57, 169/185 (1987)
- S. I. Colombano, C. Michael and M. Bualat : Goal Directed Model Inversion, Proc. of International Joint Conference on Neural Networks (IJCNN'91 Singapore), 2422/2427 (1991)
- 大山, 館:多対一対応システムの逆モデル学習の一手法, 第3回インテリジェントシステムシンポジウム, 305/310 (1993)
- 大山, 館:ビジュアルフィードバックについての一考察, 第5回生体生理工学シンポジウム, 141/144 (1990)
- E. Oyama and S. Tachi : A Study of Human Hand

- Position Control Learning—Output Feedback Inverse Model—, Proc. of International Joint Conference on Neural Networks (IJCNN'91 Singapore), 1434/1443 (1991)
- 7) D. E. Rumelhart, G. E. Hinton and R. J. Williams: Learning International Representation by Error Propagation, Parallel Distributed Processing, D. E. Rumelhart and J. L. McClelland and the PDP Research Group ed., 318/326, MIT Press (1986)
- 8) C. G. Atkeson, E. W. Aboaf, J. McIntyre and D. J. Reinkensmeyer: Model-Based Robot Learning, Robotics Research 4, Bolles R. C. and Roth B. ed., 103/110 (1988)

《付録1 出力フィードバック型逆モデル》

著者らは、人間の上肢の逆運動学問題の解法システムのモデルとして、近似的に広義のニュートン法を実現する出力フィードバック型逆モデルを提案した。

連続なシステムの入力の微小変化 Δx とそれに対応する微小変化 Δy には、

$$\Delta y = f(x + \Delta x) - f(x) \doteq A(x)\Delta x \quad (\text{A.1})$$

のような関係が成立する。上の式の逆モデルを学習要素によって獲得することを考える。学習要素 $\Phi(x, \Delta y)$ の教師信号 $\Phi'(x, \Delta y)$ として、

$$\Phi'(x, \Delta y) = \Delta x \quad (\text{A.2})$$

を提案する。(A.1)式の線形化モデル

$$\Delta y = A(x)\Delta x \quad (\text{A.3})$$

を満たす Δx は x と Δy を利用して、

$$\Delta x = A^*(x)\Delta y + (I - A^*(x)A(x))u \quad (\text{A.4})$$

と書くことができる。 $A^*(x)$ は $A(x)$ の一般化逆行列であり、 $A(x)$ の疑似逆行列(Moore-Penrose の一般化逆行列) $A^*(x)$ と、 m 行 m 列の行列 $G(x)$ を利用して、次式のように表わされる。

$$A^*(x) = A^*(x) + (I - A^*(x)A(x))G(x) \quad (\text{A.5})$$

u は Δy と無相関の m 次元ベクトルである。ここでは、 Δy が微小であることを考慮し、 Δy の 2 次以上の項を無視している。本文中の(3)式より、(A.2)式による学習の結果として、

$$\begin{aligned} \Phi(x, \Delta y) &\doteq E(\Delta x) = A^*(x)\Delta y \\ &+ (I - A^*(x)A(x))E(u) \end{aligned} \quad (\text{A.6})$$

を得る。 $\Phi(x, \Delta y)$ は(A.3)式の逆モデルである。

ここで、オフライン学習に用いる Δx の時間平均 $E(\Delta x)$ が 0 であると仮定すると、 u が Δy と無相関の項である

ことから、次式が成立する。

$$\begin{aligned} E(\Delta x) &= A^*(x)A(x)E(\Delta x) \\ &+ (I - A^*(x)A(x))E(u) \\ &= (I - A^*(x)A(x))E(u) = 0 \end{aligned} \quad (\text{A.7})$$

よって、

$$\Phi(x, \Delta y) \doteq A^*(x)\Delta y \quad (\text{A.8})$$

を得る。

この学習要素 $\Phi(x, \Delta y)$ に、現時点 k での出力誤差

$$\Delta y_d(k) = y_d - f(x(k)) \quad (\text{A.9})$$

を入力して、出力誤差のフィードバック回路を構成する。

学習要素の出力をを利用して、システムへの入力の現在値 $x(k)$ をつぎのように更新する。

$$\begin{aligned} x(k+1) &= x(k) + \Phi(x(k), \Delta y_d(k)) \\ &\doteq x(k) + A^*(x(k))(y_d - f(x(k))) \end{aligned} \quad (\text{A.10})$$

これが出力フィードバック型逆モデルの基本動作であり、 $\Delta y_d(k)$ が十分小さい領域において、本文中の(4)式の広義のニュートン法を近似的に実現している。ただし、(A.10)式は近似式であり、出力誤差 Δy_d が 0 になったとしても、(A.10)式の右辺第 2 項は 0 にならず、真の解から離れてしまう。そのため高精度の解を得ることが難しい。

[著者紹介]

大山英明(正会員)



1987 年、東京大学大学院工学系研究科修士課程修了。同年通産省工業技術院機械技術研究所入所。ロボット工学部バイオロボティクス研究室所属。テレイグジスタンス、人間の運動制御系のモデル化、神経回路、非線形最適化などの研究に従事。

館 嘉洋(正会員)



1973 年、東京大学大学院工学系研究科博士課程修了。同年同大学助手。75 年機械技術研究所入所。バイオロボティクス課長。79~80 年 MIT 客員研究員。89 年東京大学工学部助教授。92 年同教授。IMEKO TC 17(Robotics)議長。SICE フェロー(工学博士)。