

# 論文

## 直接逆モデリングによる人間の逆運動学解法システムの一学習モデル

大山 英明<sup>†</sup> 前田 太郎<sup>††</sup> 舘 暉<sup>††</sup>

A Learning Model of Human System for Solving Inverse Kinematics Problem by Direct Inverse Modeling

Eime OYAMA<sup>†</sup>, Taro MAEDA<sup>††</sup>, and Susumu TACHI<sup>††</sup>

あらまし 視覚空間上の目標点に手先を一致させるためには、適切な関節角ベクトルを計算するシステムが必要である。そのような逆運動学問題の解法システムを、人間は神経系に形成している。その構造や形成機構を解明することは、神経科学の重要な課題の一つであり、いくつかのモデルが提案されているが、それぞれ問題をかかえている。一つの手先位置の目標値を実現する関節角ベクトルは無数に存在する。上肢の逆運動学問題は不良設定問題であり、現在広く用いられている直接逆モデリングでは対応できない。本論文では、逆運動学問題の不良設定性を一部回避し、直接逆モデリングを用いて逆運動学解法システムの学習を行う学習モデルを提案する。関節角の微小変化とそれに対応する手先位置の微小変化の関係、あるいは関節角速度に対応する手先位置速度の関係は線形であり、直接逆モデリングによって、目標とする手先位置変化を実現する関節角修正量を計算する逆モデルの一種を学習できる。これを、手先位置誤差のフィードバック回路として利用することによって、逆運動学問題の解法システムを構築できる。数値実験により、提案したモデルの評価を行う。

キーワード 神経回路、逆運動学問題、直接逆モデリング、出力フィードバック型逆モデル

### 1. まえがき

視覚によって与えられた目標に手先をもっていくための腕の姿勢を決定する問題は、逆問題の一種であり、それを解くためには手先の目標位置から腕の関節角を出力する逆運動学問題の解法システムが必要である。このような解法システムを、人間は神経系に形成している。人間の神経系が、どのような機構により、逆運動学問題解法システムを実現しているかを解明することは、神経科学の重要な問題の一つであり、いくつかの理論モデルが提案されているが、それぞれ問題をかかえている。

代表的なモデルとして、人間の手先の視覚上の位置から関節角ベクトルを生成する逆運動学モデルを学習によって獲得し、それによって逆運動学問題を解くというモデルがある。逆運動学モデルの学習法として、

対象システムの出力の現在値を学習要素に入力し、学習要素の出力が対象システムの入力の現在値に一致するように学習を行い、対象システムの逆モデルを学習する逆モデル学習法が、広く用いられている。この学習法は Jordan によって直接逆モデリングと名づけられた[1]。Kuperstein[2]、坂口[3]らは直接逆モデリングによって逆運動学モデルを学習し、逆運動学解問題を解くという解法システムのモデルを提案した。しかしながら、直接逆モデリングは、不良設定問題に対応できないという問題点が指摘されている。一つの手先位置の目標値を実現する関節角ベクトルは無数に存在する。上肢の逆運動学問題は不良設定問題であり、直接逆モデリングでは対応できない[1]。

本論文では、逆運動学問題の不良設定性を、学習対象を変更することによって一部回避し、直接逆モデリングを利用して、逆運動学解法システムを学習する学習モデルを提案する。関節角の微小変化とそれに対応する手先位置の微小変化の関係は線形であり、直接逆モデリングによって、目標とする手先位置変化を実現する関節角修正量を出力する逆モデルの一種を学習できる。この逆モデルを、手先位置誤差のフィードバッ

† 機械技術研究所、つくば市

Mechanical Engineering Laboratory Tsukuba-shi, 305 Japan

†† 東京大学工学部、東京都

Faculty of Engineering, The University of Tokyo, Bunkyo-ku, Tokyo, 113 Japan

ク回路として用いることによって、逆運動学問題の解法システムを構築できる。数値実験により、提案したモデルの評価を行う。本モデルの構成には、いまだ不自然な点も存在するが、冗長アームの制御が可能であり、人間の逆運動学解法システムのたたき台となり得ると考えられる。

## 2. 人間の手先位置制御系の一モデル

### 2.1 問題の定式化

最終的に運動を起こすアクチュエータは筋肉であり、最終的な運動指令は筋長座標によって記述すべきであるが、動力学を無視した逆運動学問題では、筋長座標と関節座標を同一視することができ、本論文では、関節角指令をもとに論述を進める。

視覚によって作業空間上の  $n$  次元手先位置ベクトル  $\mathbf{x}$  が得られるものとする。 $m$  次元関節角ベクトルを  $\boldsymbol{\theta}$  として、上肢の運動学的関係を

$$\mathbf{x} = \mathbf{f}(\boldsymbol{\theta}) \quad (1)$$

とする。手先位置  $\mathbf{x}$  の目標値  $\mathbf{x}_d$  が与えられたとき、

$$\mathbf{x}_d = \mathbf{f}(\boldsymbol{\theta}_d) \quad (2)$$

を実現する関節角ベクトルの値  $\boldsymbol{\theta}_d$  を計算する逆運動学問題を考える。

ここで、理想的な学習要素を考える。入力が  $t$  であるとき、その出力を  $\Phi(t)$  とし、与えられる教師信号を  $\Phi'(t)$  とする。

$$\Phi'(t) = \mathbf{s}_j \quad (3)$$

のように教師信号  $\mathbf{s}_j$  ( $j=1, 2, 3, \dots$ ) が与えられた場合、最終的に、

$$\Phi(t) = E(\mathbf{s}_j) \quad (4)$$

となるように学習が行われるものとする。 $E(\mathbf{s}_j)$  はベクトル  $\mathbf{s}_j$  の平均値を示す。また、 $\Phi(t)$  は、入力  $t$  の大部分の領域において、1階連続微分可能な関数であり、補間機能により、有限個の適切に選ばれた代表点の学習によって、入力の全域にわたる学習が可能であるものと仮定する。現在、提案されている学習型の神経回路モデルの多く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、例えば、バックプロパゲーション学習を行う多層神経回路[4]や Kohonen のトポグラフィックマッピング[5]等がある。このような理想的な学習要素によって、逆運動学問題解法システムを獲得する学習のモデルの一案を提案する。

### 2.2 人間の逆運動学解法システムに関する一仮説

川人は人間の随意運動制御の計算理論モデルとして、(I) 作業座標系における軌道計画、(II) 作業座標系

から関節角や筋長などの身体座標系への座標変換、(III) 軌道を達成するための関節角の運動指令を計算する制御問題という三つの階層より構成される情報処理のモデルを提案した[6]。本論文では、階層(II)の座標変換問題を考察する。

人間は、空間上の1点を目標点として与えられた場合、視覚フィードバックがあれば、目標点に高精度で到達できる。一方、自分の手先位置が見えない状態では、その精度は大きく悪化する[7]～[9]。この事実を考慮すれば、人間の逆運動学問題を解く神経機構が、視覚座標系上の手先の絶対位置と絶対的な体性感覺との対応関係に主として依存している可能性は低い。人間の視覚においては、相対位置測定の精度や位置変化の感知精度は高いという事実を考慮し[10], [11]、筆者らは、人間の逆運動学解法システムは、視覚座標系上の手先位置と体性感覺の対応関係というよりはむしろ、両者の変化量の関係に基づいて構成されているという仮説を立てている。川人は、作業座標系の位置の変化量目標値を筋長の修正量に変換する疑似逆行列(Moore-Penrose の一般化逆行列)を、両者の変化量に基づいて学習するモデルを提案した[12]。但し、その学習は、最急降下法に基づく適応則に基づいて行われており、生体のモデルとしては、問題があると考えられる。

頭頂連合野においては、手先の運動の方向によって、神経細胞の発火頻度が決定される神経細胞が多数見つかっている。Georgopoulos らは、サルの運動野を調べ、特定の方向に手を動かすとき、高頻度で発火する神経細胞を発見した。また、各細胞の固有の方向に、細胞の発火頻度が静止水準からどれだけ増大、または減少しているかによって重み付けして、総和をとることによって得られるベクトルは、手先運動の方向をよく表していること、また、ベクトルの長さが速度と相関があることを示した。猿が手を伸ばすとき、始点によって運動皮質の活動の分布領域が異なることも発見されている[13]～[15]。Georgopoulos の説に対して、いくつかの修正・異論が唱えられているが[16]、頭頂連合野および運動野において、運動の方向に強い相関のある神経細胞があり、運動野からは身体座標に基づいて信号出力が行われることから、頭頂連合野と運動野、およびその間の前頭頂連合野を含む経路において、作業座標から身体座標への変換機構が存在する可能性が高い。

手先位置の変化量ベクトルや速度ベクトルは大きさ

を無視すれば運動の方向に一致している。生理学的知見からも、手先位置制御においては、位置の変化量が重要な情報となっていることが期待される。また、始点によって運動皮質の活動の分布領域が異なることから、関節角ベクトルの状態も重要な情報であることがわかる。本論文では、関節角ベクトル  $\theta$  と手先位置の変化指令  $\Delta x_d$  を入力とし、 $\Delta x_d$  を関節角ベクトルの変化指令  $\Delta \theta_d$  に変換する座標変換回路の学習モデルを提案し、逐次的に関節角ベクトルを生成する逆運動学問題解法システムのモデルを提案する。

文献[7]～[9]より、人間の神経系が視覚と体性感覚の絶対的な対応に基づく逆運動学モデルをもっていることは明らかであり、将来的には逆運動学解法システムのモデルに組み込む予定であるが、今回は、これを無視してモデル化を行う。次節で述べる出力誤差のフィードバック回路が獲得されれば、フィードバック誤差学習則[6]によって、逆運動学モデルの学習は可能であることを述べておく。

### 2.3 出力フィードバック型逆モデル

Bullock と Grossberg らは、Georgopoulos らの実験結果を説明する上肢運動制御系の計算モデルとして、最終的な目標位置  $x_e$  と時刻  $t$  における現在の手先位置指令  $x_d(t)$  の差

$$\Delta x_e(t) = x_e - x_d(t) \quad (5)$$

の情報をもとに、逐次的に手先位置目標値  $x_d(k)$  を更新するというモデルを提案した[17]。適切に上肢が制御され、直線的に手先位置が変化していくものとすると、 $\Delta x_e(t)$  の方向が一定であることが、Georgopoulos らの実験結果に対応するとしている。このように、視覚座標系において目標軌道が計算され、逐次的に手先の目標位置が与えられるものと仮定する。

以下、離散系によって、運動制御系をモデル化するものとし、サンプリング時間を  $\Delta t$  として、時刻  $t_k$  を  $t_k = k\Delta t$  とし、時刻  $t_k$  におけるベクトル  $s(t_k)$  を、 $s(k)$  と略記するものとする。 $\Delta t$  として、人間が視覚刺激を受けてから運動を起こすまでの時間遅れ 0.2 秒前後の値を想定する。

手先位置の目標値  $x_d(k)$  の変化量

$$x_d(k) = x_d(k+1) - x_d(k) \quad (6)$$

に、出力誤差

$$e(k) = x_d(k) - x(k) \quad (7)$$

のフィードバック項を付加し、手先位置の変化量の目標値  $\Delta x_d'(k)$  を、適切な係数  $K$  を利用して、

$$\Delta x_d'(k) = \Delta x_d(k) + K e(k) \quad (8)$$

のように構成する。 $\Delta x_d'(k)$  を実現する関節角ベクトルの修正量  $\Delta \theta_d(k)$  によって、

$$\theta(k+1) = \theta(k) + \Delta \theta_d(k) \quad (9)$$

のように関節角ベクトルを更新すれば、手先を  $x_d(k)$  に追従させることができる。対象システム  $f(\theta)$  のヤコビ行列

$$J(\theta) = \frac{\partial f(\theta)}{\partial \theta} \quad (10)$$

とすると、関節角変化量  $\Delta \theta_d(k)$  は、例えば、ヤコビ行列  $J(\theta)$  の一般化逆行列  $J^*(\theta)$  を利用して、

$$\Delta \theta_d(k) = J^*(\theta(k)) \Delta x_d'(k) \quad (11)$$

のように計算できる。

筆者らは、人間の神経系が式(11)のような座標変換回路を学習によって獲得すると考える。関節角ベクトル  $\theta$  の変化が滑らかであるとき、関節角ベクトルの十分小さな変化量を  $\Delta \theta$  とし、それに対応する手先位置の変化量  $\Delta x$  とする。両者には近似的に

$$\Delta x = J(\theta) \Delta \theta \quad (12)$$

という線形の関係がある。座標変換を学習する神経回路への入力を関節角ベクトル  $\theta$  と  $\Delta x$  とし、その出力を  $\Phi(\theta, \Delta x)$  とする。その教師信号  $\Phi'(\theta, \Delta x)$  を

$$\Phi'(\theta, \Delta x) = \Delta \theta \quad (13)$$

とすると、この教師信号によって、式(12)の逆モデルを獲得でき、オフライン学習の場合には、

$$\Phi(\theta, \Delta x) = J^*(\theta) \Delta x \quad (14)$$

を実現できる。学習の詳細については、3. で述べる。以上をまとめると、次式のような手先位置制御系のモデルを得る。

$$\theta(k+1) = \theta(k) + \Delta \theta_d(k)$$

$$\Delta \theta_d(k) = \Phi(\theta(k), \Delta x_d'(k)) = J^*(\theta(k)) \Delta x_d'(k)$$

$$\Delta x_d'(k) = x_d(k+1) - x_d(k) + K e(k) \quad (15)$$

なお、ここで、 $K=1$  とすれば、

$$\Delta x_d'(k) = x_d(k+1) - x(k) \quad (16)$$

となる。手先位置制御系は、

$$\theta(k+1) = \theta(k) + J^*(\theta(k))(x_d(k+1) - f(\theta(k))) \quad (17)$$

となり、広義のニュートン法を近似的に実現している。このように、出力誤差のフィードバックを利用して、反復改良演算に基づいて、逆問題の解を求めるシステムを、筆者らは出力フィードバック型逆モデルと呼んでいる[18], [19]。これは通常の意味での逆モデルとは言えないが、反復改良の結果として、逆モデルと同様の働きをするため、このように呼んでいる。出力フィードバック型逆モデルの構成を図 1 に示す。図中の  $z-1$

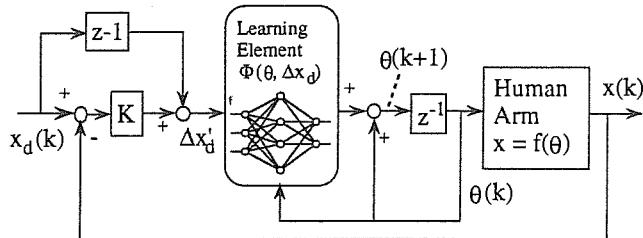


図1 出力フィードバック型逆モデルの構成  
Fig. 1 Configuration of Output Feedback Inverse Model.

は信号の増分を計算する制御要素である。

本論文で示した出力フィードバック型逆モデルの構成は、工学的には、精度が十分とは言えず、また、学習時間がかかるといったいくつかの弱点を抱えている。工学的逆運動学問題解法システムとしては、川人らのフィードバックゲインの学習法[12]や、筆者らが提案した工学的改良案[20]を利用できる。

#### 2.4 速度・加速度に着目した出力フィードバック型逆モデル

関節角と手先位置の速度の関係

$$\dot{x} = J(\theta) \dot{\theta} \quad (18)$$

は線形であり、関節角の微小変化と同様に、直接逆モデリングによって、逆モデルの獲得が可能である。また、関節角と手先位置の加速度の関係

$$\ddot{x} = J(\theta) \ddot{\theta} + \left[ \frac{\partial J(\theta)}{\partial \theta} \dot{\theta} \right] \dot{\theta} \quad (19)$$

も、関節角加速度と手先位置加速度に着目すれば、線形であり、直接逆モデリングによって、逆モデルの学習が可能である。速度や加速度の関係に着目した逆運動学解法システムの構成法については、付録2.に示す。

#### 2.5 静的な逆運動学問題の解法

本節では、目標軌道が明示されず、目標手先位置の終端値のみが指定される静的な逆運動学問題について述べる。与えられた目標手先位置に手先を一致させる関節角ベクトルを計算するためには、現在の手先位置と目標手先位置とを連続に結ぶ目標軌道を生成し、それに追従するような手先位置制御を行えばよい。関節角がストロークエンドに達したり、ヤコビ行列が特異になるような姿勢に達したりして、軌道に追従できない場合には、ランダムに関節角ベクトルの初期値を変更し、再び目標手先位置に到達するような目標軌道を生成し、その軌道へ追従する過程を繰り返すことによって、最終的には目標点に到達できる。

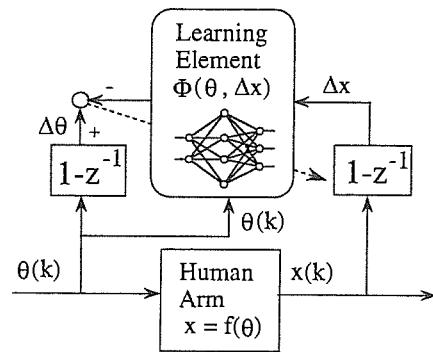


図2 学習要素のための教師信号  
Fig. 2 Teaching signal for learning element.

### 3. 座標変換回路の学習

本章では、手先の位置誤差を関節角ベクトルの変化量に変換する神経回路  $\Phi(\theta, \Delta x)$  の学習について述べる。式(13)による  $\Phi(\theta, \Delta x)$  の学習の様子を図2に示す。

#### 3.1 直接逆モデリングによるオフライン学習

本論文において、人が手先位置の制御を意図していない運動時に、神経回路の学習を行うことをオフライン学習と呼ぶ。

入力の変化  $\Delta\theta$  が十分小さな領域においては、式(12)のような線形近似が可能である。 $\Phi(\theta, \Delta x)$  を理想的な学習要素とすると、式(13)に従って学習を行った場合、式(12)を満たす  $\Delta\theta$  を  $\Delta\theta^*$  とすれば、式(4)より、

$$\Phi(\theta, \Delta x) \doteq E(\Delta\theta^*) \quad (20)$$

となるように、学習が行われる。

$n=m$  の場合、 $J(\theta)$  が正則行列であれば、式(12)の  $\Delta x$  に対応する  $\Delta\theta^*$  は唯一であり、

$$\Phi(\theta, \Delta x) \doteq E(\Delta\theta^*) = J(\theta)^{-1} \Delta x \quad (21)$$

を得る。 $n < m$  の場合において、 $J(\theta)$  がフルランクの場合、式(12)を満たす  $\Delta\theta$  は無数に存在し、 $J(\theta)$  の一般化逆行列  $J^*(\theta)$  と、 $J(\theta)$  の疑似逆行列 (Moore-Penrose の一般化逆行列)

$$J^*(\theta) = J^T(\theta)(J(\theta)J^T(\theta))^{-1} \quad (22)$$

を利用して、

$$\Delta\theta^* = \Delta\theta^*(\Delta x, u) = J^*(\theta)\Delta x + (I - J^*(\theta)J(\theta))u \quad (23)$$

と書くことができる。 $\Delta\theta^*$  は  $\Delta x$  と  $u$  の関数であるだけでなく、 $\theta$  の関数もあるが、 $\theta$  は省略する。 $u$  は  $\Delta x$  と無相関の  $m$  次元ベクトルである。 $J^*(\theta)$  は、 $J^*(\theta)$  と  $m$  行  $n$  列の行列  $G(\theta)$  を利用して、

$$J^*(\theta) = J^*(\theta) + (I - J^*(\theta)J(\theta))G(\theta) \quad (24)$$

と書くことができる。式(4)より、

$$\begin{aligned}\Phi(\theta, \Delta x) &= E(\Delta\theta^*(\Delta x, u)) \\ &= J^*(\theta)\Delta x + (I - J^*(\theta)J(\theta))E(u)\end{aligned}\quad (25)$$

を得る。 $E(u)$ の値にかかわらず、

$$J(\theta)\Phi(\theta, \Delta x) = \Delta x \quad (26)$$

が成立し、 $\Phi(\theta, \Delta x)$ は式(12)の近似的逆モデルとなっている。以上のように、式(13)の学習則によって、座標変換回路の学習が可能である。

$J(\theta)$ がフルランクの場合、 $(I - J^*(\theta)J(\theta))$ のランクは  $m-n$  となる。式(23)より、 $\Delta\theta^*$  は  $\Delta\theta$  の部分空間に分布する。 $\Delta\theta^*$  の分布する  $m-n$  次元空間の体積要素を  $dv$  とする。学習に用いる  $\Delta\theta$  の分布を表す確率密度関数を  $p(\Delta\theta)$  とすると、式(25)は、

$$\begin{aligned}\Phi(\theta, \Delta x) &= E(\Delta\theta^*(\Delta x, u)) \\ &= \frac{\int_Q p(\Delta\theta^*(\Delta x, u))\Delta\theta^*(\Delta x, u)dv}{\int_Q p(\Delta\theta^*(\Delta x, u))dv}\end{aligned}\quad (27)$$

と表すことができる。積分領域  $Q$  は  $\Delta\theta^*(\Delta x, u)$  の分布する全空間である。 $\Delta\theta$  が大きな領域では、 $p(\Delta\theta)$  の値は 0 とみなせるものとする。

オフライン学習が行われる、手先位置制御を意図しない一般の運動では、 $\theta$  の大部分の領域で、

$$p(\Delta\theta) = p(-\Delta\theta) \quad (28)$$

と考えることができる。よって、

$$\Phi(\theta, 0) = \frac{\int_Q p(\Delta\theta^*(0, u))\Delta\theta^*(0, u)dv}{\int_Q p(\Delta\theta^*(0, u))dv} = 0 \quad (29)$$

である。 $\Phi(\theta, \Delta x)$  が、大部分の領域において、 $\Delta x$ について一階連続微分可能な関数であることから、

$$\begin{aligned}\Phi(\theta, \Delta x) &= \Phi(\theta, 0) + \left[ \frac{\partial \Phi(\theta, \Delta x)}{\partial \Delta x} \right]_{\Delta x=0} \Delta x + O(\Delta x^2)\end{aligned}\quad (30)$$

と展開できる。 $O(\Delta x^2)$  は  $\Delta x$  に関して 2 次以上の項の総和を示す。式(25), (29), (30)より、オフライン学習の結果、 $\Delta x$  が十分微小な領域では、式(14)が成立する。

手先位置制御を意図しない一般の運動では、 $p(\Delta\theta)$  は適当な円 2 次超曲面上で一定とみなすことができ、 $m$  行  $m$  列の適当な正定対称行列  $P$  と適当なスカラ関数  $g(S)$  を利用して、

$$p(\Delta\theta) = g(\Delta\theta^T P^{-1} \Delta\theta) \quad (31)$$

が成立するものとみなせる。なお、式(31)が成立し、かつ、 $\Delta\theta$  の分布が正規分布に従うとすると、 $\Delta\theta$  の共分散行列は、適当なスカラ  $\lambda$  を利用して、

$$E(\Delta\theta \Delta\theta^T) = \lambda P \quad (32)$$

と表すことができる。

付録 1. に示す計算によって、学習した  $\Delta x$  の範囲において、

$$\Phi(\theta, \Delta x) = PJ^T(JPJ^T)^{-1} \Delta x \quad (33)$$

を得ることができ、式(14)が成立する。式(33)の右辺は、式(12)を満たす  $\Delta\theta$  の中で評価関数

$$S = 1/2 \Delta\theta P^{-1} \Delta\theta \quad (34)$$

を最小化する。

各関節の動きに相関がなく、 $P$  が対角行列である場合、評価関数  $S$  は

$$S = \frac{1}{2} \sum_{i=1}^m \frac{\Delta\theta_i^2}{P_{ii}} \quad (35)$$

となる。この評価関数が最小化されるということは、「ふだんの運動でよく動いている関節が大きく動く」と定性的に解釈できる。式(33)の座標変換回路を用いて、関節角ベクトルの逐次更新を行う場合、手先の目標位置  $x_d(k)$  が滑らかに変化するならば、関節角ベクトル  $\theta(k)$  も同様に滑らかに変化することが保証される。

冗長ロボットアームの制御のために Whitney は疑似逆行列を利用した先端位置変位の関節角変位への変換法を提案した[21]。川人は最小ノルム解を近似的に得るために、疑似逆行列を近似するフィードバックゲインの学習法を提案している[12]。本論文で提案した学習則によって得られる結果は、これらを近似している。辻らは、関節のインピーダンスを考慮して、類似の逆運動学解を得ている[22]。本論文の結果とインピーダンス等の動力学特性との関係の考察は今後の課題である。

### 3.2 オンライン学習

本論文において、人間が手先位置の制御を意図し、式(15)による手先位置制御を行っているときに、学習を行うことをオンライン学習と呼ぶ。座標変換回路によつて計算した関節角修正量  $\Delta\theta_d$  を教師信号とすることにより、オンライン学習が可能である。オンライン学習においても、学習要素の入力空間の 1 点  $(\theta, \Delta x)$  で学習が行われていれば、その点の近傍においては、式(26)が成立し、学習要素は座標変換回路を学習できる。但し、式(29)が成立するとは限らない。

関節角の修正量  $\Delta\theta_d$  の計算が

$$\Delta\theta_d = \Phi(\theta, \Delta x_d) \quad (36)$$

のように行われるものとする。学習時において、座標変換回路への入力は関節角の現在値  $\theta$  と、関節角の変化量  $\Delta\theta_d$  に対応する手先位置の変化  $\Delta x$  であり、次式のような教師信号によって学習が行われる。

$$\Phi'(\theta, \Delta x) = \Delta \theta_d = \Phi(\theta, \Delta x_d)$$

$$\Delta x = f(\theta + \Delta \theta_d) - f(\theta) \quad (37)$$

この学習は、Colombano らの提案した目標指向型モデル反転 (Goal Directed Model Inversion)[23]を、次のようなシステム

$$\begin{aligned} \Delta x &= g(\theta, \Delta \theta) \\ &= f(\theta + \Delta \theta) - f(\theta) \end{aligned} \quad (38)$$

に対して、適用したものとなっている。学習が十分進行した段階においては、教師信号  $\Delta \theta_d$  は  $\Delta x$  に対して一意に定まり、オフライン学習時と異なり、 $\Delta \theta$  が十分小さいという条件は必要でなくなる可能性が期待できる。しかしながら、オンライン学習の場合、式(29)が成立しないため、 $\Phi(\theta, \Delta x_d)$ への入力  $\Delta x_d$  が  $\mathbf{0}$  になってしまい、 $\Phi(\theta, \Delta x_d)$  の値は  $\mathbf{0}$  にならず、関節角ベクトルの更新が起こるという問題がある。

### 3.3 学習についての考察

オフライン学習によって、学習を行う場合、最終的な学習結果は、教師信号の性質に依存し、学習要素の初期状態には依存しない。一方、順逆モデリング[1]、フィードバック誤差学習則[6]、あるいは提案したオンライン学習によって学習を行った場合、教師信号が学習要素の状態によって決定されるため、学習の結果は、学習要素の初期状態に依存する。オフライン学習とオンライン学習の両方が行われた場合、学習結果は、オフライン学習に用いられた教師信号の性質に依存することになる。

オンライン学習のみでは、学習要素の初期状態によっては、解法システムの学習が成功しない可能性がある。また、 $\Phi(\theta, \mathbf{0})$  の値が  $\mathbf{0}$  にならないという問題点がある。一方、オフライン学習のみでは、実際に行いたい運動状態で、目標指向性のある学習を行うことは困難である。よって、筆者らはオフライン学習とオンライン学習の両方が行われていると考える。この学習を複合学習 (HL : Hybrid Learning) と呼ぶことにする。

人間は、幼児期に、反射的な運動から始まって、さまざまな運動を繰り返した後、物をつかむことができるようになる[24], [25]。このとき、多数回のオフライン学習が行われ、逆運動学問題解法システムが形成されるものと想定される。また、さまざまな運動を行いつつ成長し、常に逆運動学解法システムの調整が行われているものと考えられる。

## 4. シミュレーション

提案したモデルの性能を評価するために、数値実験

を行う。2次元平面上を動くマニピュレータアームの逆運動学問題を考える。2次元平面上で動く、3自由度アームの関節角ベクトル  $(\theta_1, \theta_2, \theta_3)$  とその手先位置  $(x, y)$  の関係を

$$\begin{aligned} x &= x_0 + L_1 \cos(\theta_1) + L_2 \cos(\theta_1 + \theta_2) \\ &\quad + L_3 \cos(\theta_1 + \theta_2 + \theta_3) \\ y &= y_0 + L_1 \sin(\theta_1) + L_2 \sin(\theta_1 + \theta_2) \\ &\quad + L_3 \sin(\theta_1 + \theta_2 + \theta_3) \end{aligned} \quad (39)$$

とする。これは、水平面や垂直平面上において運動を行っている上肢のモデルである。寸法は  $L_1$  が  $0.30\text{ m}$ ,  $L_2$  が  $0.25\text{ m}$ ,  $L_3$  が  $0.15\text{ m}$  とする。垂直面上の運動を想定し、肩関節に相当する  $\theta_1$  の可動範囲は  $[-30^\circ, 120^\circ]$ , 肘関節に相当する  $\theta_2$  の可動範囲は  $[0^\circ, 120^\circ]$ , 手首関節に相当する  $\theta_3$  の可動範囲を  $[-60^\circ, 60^\circ]$  とする。

このようなアームについて、手先位置  $(x, y)$  を実現する関節角ベクトル  $(\theta_1, \theta_2, \theta_3)$  を求める逆運動学問題の解法システムを獲得するシミュレーションを行う。図3にアームの構成を示す。以下、出力フィードバック型逆モデルを OFIM (Output Feedback Inverse Model) と略す。簡単のため式(15)において、 $K=1$  とおく。比較のために、学習要素を用いずに、式(17)の右辺を計算によって求め、逆運動学問題を解く数値解法方式を用意する。これを NM (Numerical Method) と略す。

以下に述べるような目標軌道について、逆運動学問題を解く試行を行い、軌道の追従誤差によって、解法システムの評価を行う。

まず一様乱数によって関節角ベクトルの初期値  $\theta(0)$  を発生させ、そのときのアーム先端位置  $x(0)$  を初期目標値  $x_s$  として定め、次に再び正規乱数  $\omega$  によってアーム先端位置の変化量  $\Delta x_{se}$  の第  $i$  成分を

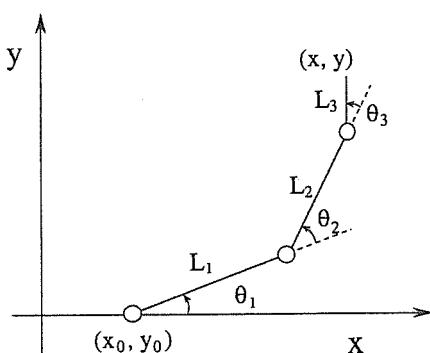


図3 アームの構成  
Fig. 3 Configuration of arm.

$$\Delta x_{sei} = 0.2\omega \text{ (m)} \quad (40)$$

のように定め、次式のように手先位置の最終的な目標値  $x_e$  を定める。

$$x_e = x_s + \Delta x \quad (41)$$

これら目標値と初期値の組に対し、目標軌道を

$$x_d(k) = \begin{cases} (1-k/T)x_s + k/Tx_e & (0 \leq k \leq T) \\ x_e & (T \leq k \leq 2T) \end{cases} \quad (42)$$

のように定義し、提案する逆運動学解法システムによって、アーム先端を目標軌道へ追従させる。但し、運動学的に実現不可能な軌道は除くものとする。今回のシミュレーションでは  $T$  を 5 とおく。サンプリングタイム  $\Delta t$  を 0.2 s とすると、手先の目標速度の標準偏差は  $0 \leq k \leq T$  において、0.2 m/s である。

多数回の試験を行い、追従誤差  $e(k)$  の RMS 誤差によって、解法システムの性能を評価する。但し、計算中に、関節角の可動範囲を超えた軌道は失敗したものとする。

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 ( $y = \tanh(x)/2$ ) 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。座標変換を学習する神経回路は入力層より順に、5, 15, 15, 3 個のニューロンによって構成される。

神経回路の学習法としては、バックプロパゲーション法を用いる。バックプロパゲーション法は、人間の神経系で用いられている可能性は低い。本論文で提案されたモデルの動作の検証においては、学習要素の学習法は何を選んでもよいため、簡便なバックプロパゲーション法を用いることにする。Kohonen のトポグラフィックマッピング等のより現実的な学習要素の利用は今後の課題である。 $i$  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

$$S^{(i)} = |\Phi'^{(i)} - \Phi^{(i)}|^2 \quad (43)$$

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  $\eta$ 、慣性率を  $\alpha$  とすると、次式のように計算される。

$$\Delta w_j^{(i)} = -\eta \frac{\partial S^{(i)}}{\partial w_j} + \alpha \Delta w_j^{(i-1)} \quad (44)$$

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。

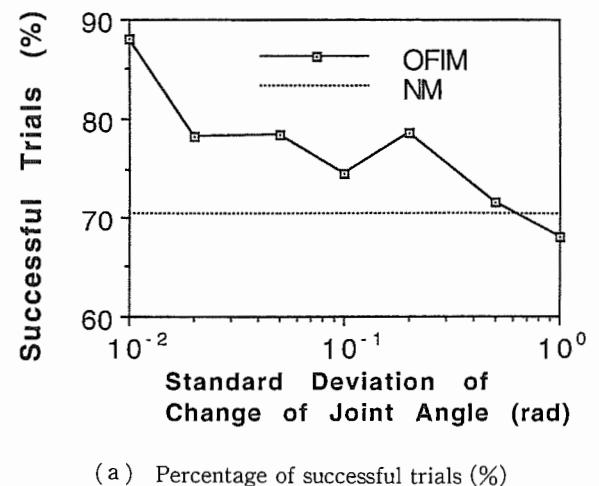
#### 4.1 オフライン学習

教師信号の性質と OFIM による手先制御の精度の関係を調べるために、オフライン学習のシミュレーションを行う。関節の初期姿勢を一様乱数によって生成し、繰り返して、関節角を変化させ、そのときの手先位置の変化量を観測し、式(13)に従って学習を行う。関節角の変化は、正規乱数  $\omega$  を利用して、次式のように生成する。

$$\Delta \theta_i = \sigma \omega \quad (45)$$

$\sigma$  は関節角の変化量の標準偏差である。サンプリングタイム  $\Delta t$  を 0.2 s とすると、 $\sigma=0.1$  は、0.5 rad/s に相当する。式(44)の学習率  $\eta$  は  $1.0 \times 10^{-3}$ 、慣性率  $\alpha$  は 0.5 とする。

関節角変化の標準偏差  $\sigma$  の変化に対する解法システムの性能の変化を図 4 に示す。図 4 の(a)は式(42)の軌道への追従動作が、関節角の可動範囲内で成功する確率の変化であり、(b)は出力の RMS 誤差の変化である。



(a) Percentage of successful trials (%)

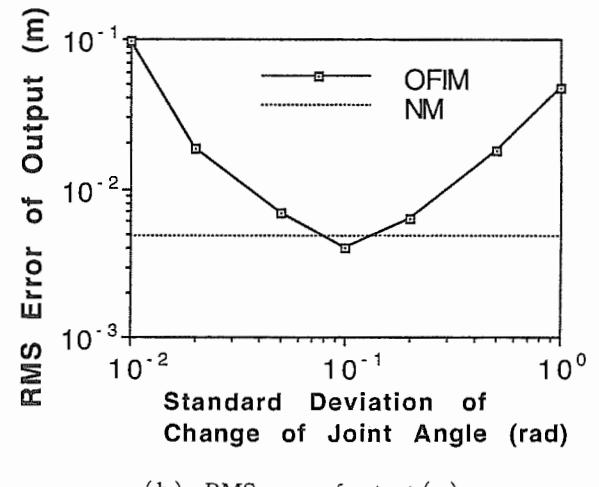
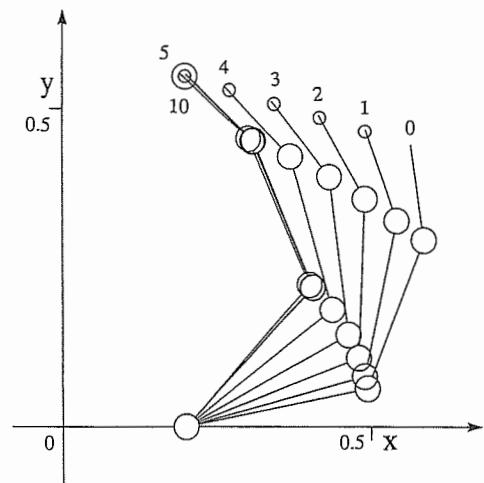


図 4 オフライン学習による出力フィードバック型逆モデルの性能

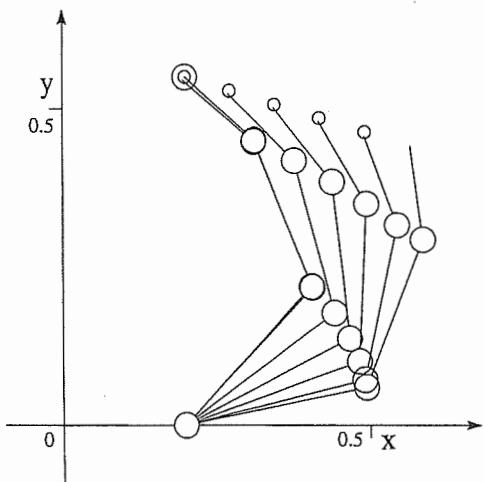
Fig. 4 Performance of OFIM after offline learning.

図中の NM は、数値解法方式のシミュレーション結果である。オフライン学習において、 $\sigma$ が適切であれば、提案法は数値解法方式に迫る精度をもっていることが判明した。人間が実際の学習において用いている信号の $\sigma$ の値を検討することは、今後の課題である。

図 5 に、前述の目標軌道への追従の様子の一例を示す。図 5(a)において、手先についている番号は式(42)の $k$ の値である。図中の小さな円は、各 $k$ の値に対応する目標手先位置を中心とし、その半径は 0.01 m の円である。図中の大きな円は、手先位置の最終的な目標値 $x_e$ を中心とし、その半径は 0.02 m である。OFIM によって生成されるアーム運動は、数値計算によって生成されるアームの運動と非常によく似ている。



(a) Output feedback inverse model



(b) Numerical method

図 5 手の軌跡(オフライン学習)  
Fig. 5 Path of hand. (Offline learning)

#### 4.2 オンライン学習

オンライン学習においては、式(42)によって生成される軌道に追従する試行を行いつつ、学習を行い座標変換回路を獲得するシミュレーションを行う。式(15)の反復ごとに学習を行うものとし、1 回の試行当り 10 回の学習を行っている。オンライン学習のみで、学習を行ったが 20 種類の初期状態から出発させたにもかかわらず、十分な精度の解法システムを得ることができなかつた。オンライン学習単独では不十分であることが判明した。

そのため、前節と同様の方法で、 $\sigma$ を 0.5 (rad) として、10 万回のオフライン学習を行った後、オンライン学習を行う。式(44)の学習率 $\eta$ は $2.0 \times 10^{-4}$ 、慣性率 $\alpha$ は 0.5 とする。学習率は、不安定にならないように、オフライン学習時よりも小さくした。

図 6 に、学習の様子を示す。試行を繰り返すにつれて、出力の RMS 誤差が減少し、逆運動学解法システムとしての性能が向上している。但し、試行が $10^7$  回を超えた時点において、RMS 誤差の増加傾向が見られた。図 7 に、1000 万回のオンライン学習を行った解法システムによる目標軌道追従の一例を示す。

比較的良好な初期値を得て、学習を始めたにもかかわらず、オンライン学習は、オフライン学習時に比べて精度は低い、また、オンライン学習のみでは、しばしば不安定になり、性能が悪化する場合が多かった。3.3 で述べたように、単純なオンライン学習のみで、学習が行われている可能性は小さいと考えられる。

#### 4.3 オフライン・オンライン複合学習

オンライン学習と同時にオフライン学習を行う複合学習について、シミュレーションを行う。

本節のシミュレーションでは、4.1 と異なり、オフライン学習においても、より現実の人間の運動に近い信号を用いる。軌道追従の試行において、前の回の試行の終了時の状態から、新たに関節角ベクトルの初期値 $\theta(0)$ を設定する際の腕の運動時に、オフライン学習を行うものとする。このときの関節角が

$$|\Delta\theta| = 0.25 \text{ (rad)} \quad (46)$$

だけ変化するごとに、学習を行うものとする。0.25 rad は、サンプリング間隔を 0.2 s とすると、1.25 rad/s に相当する。式(44)の学習率 $\eta$ は $5.0 \times 10^{-4}$ 、慣性率 $\alpha$ は 0.5 とする。

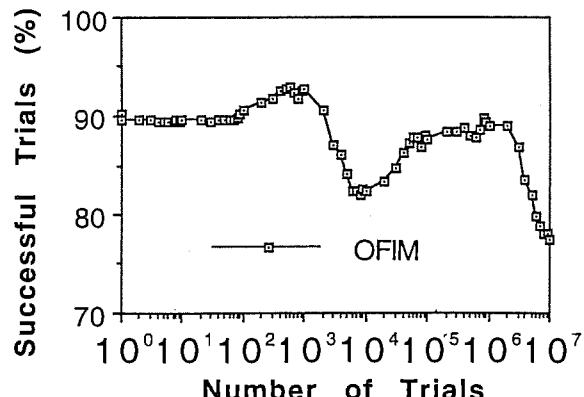
図 8 に、学習の進行の様子を示す。学習によって、RMS 誤差が減少し、解法システムとしての性能が向上していることがわかる。 $10^7$  回の試行を終えても、更に精度は向上し、 $10^8$  回の試行終了後、RMS 誤差は 5.03

$\times 10^{-3}$  mまで減少した。学習回数は、1回の試行について、平均16.3回である。図9に軌道追従の様子を示す。オフライン学習時と同様、数値解法の軌跡と非常

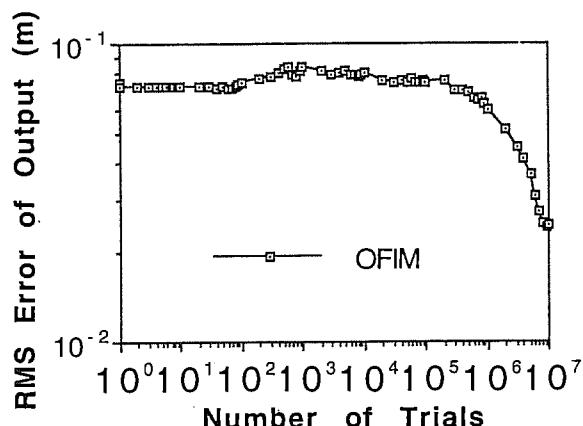
によく似ている。

#### 4.4 静的な逆運動学問題の解法

前節の複合学習によって獲得された逆運動学問題解



(a) Percentage of successful trials (%)



(b) RMS error of output (m)

図6 オンライン学習のシミュレーション結果  
Fig. 6 Simulation result of online learning.

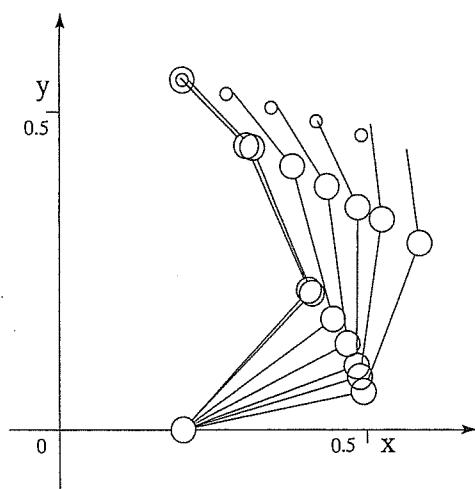
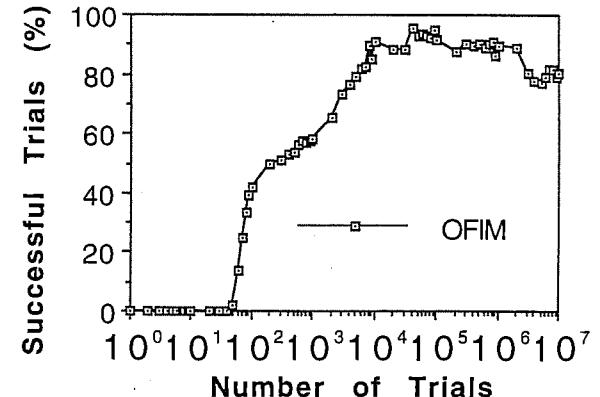
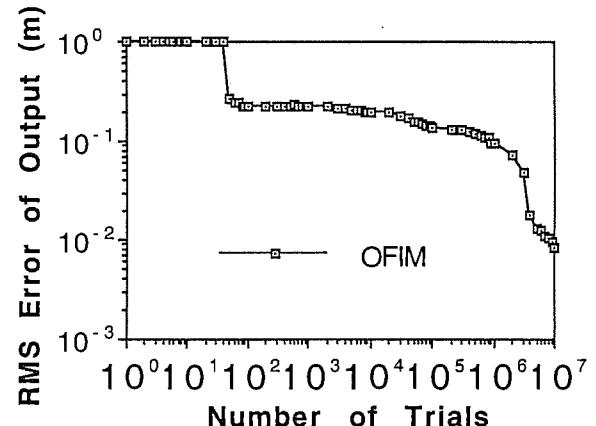


図7 手の軌跡(OFIM, オンライン学習)  
Fig. 7 Path of hand. (OFIM, Online learning)



(a) Percentage of successful trials (%)



(b) RMS error of output (m)

図8 複合学習のシミュレーション結果  
Fig. 8 Simulation result of hybrid learning.

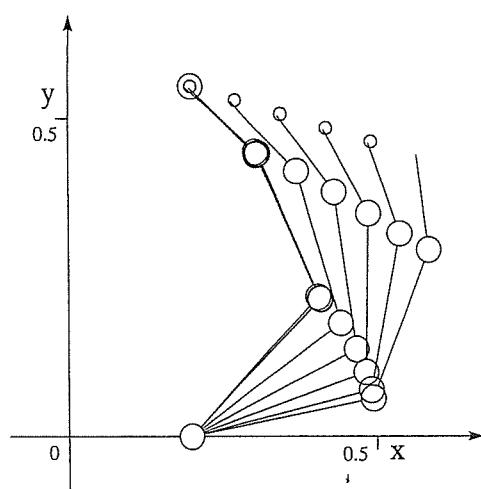


図9 手の軌跡(OFIM, 複合学習)  
Fig. 9 Path of hand. (OFIM, Hybrid learning)

法システムによって、静的な逆運動学問題を解く試行を行う。まず一様乱数によって関節角ベクトル  $\theta$  を発生させ、そのときのアーム先端位置を目標手先位置  $x_d$  として定め、解法システムによって出力された逆運動学解の精度を手先位置の RMS 誤差によって評価する。評価に用いる  $x_d$  の個数は 1 万個とする。

OFIM では、2.5 で述べたように、与えられた目標手先位置  $x_d$  に対して、一様乱数によって関節角ベクトルの初期値  $\theta(0)$  を生成し、式(42)によって、目標軌道を定め、手先を追従させる。手先位置精度の目標値を定め、手先位置誤差が目標値以下にならなかった場合には、初期値を変更して、再び目標軌道を定め、追従動作を行う。初期値変更回数の上限は 20 回とする。20 回の初期値変更を行っても、目標精度を達成できなかつた場合には、それまでの結果のうちで、手先位置誤差が最小になったものの値を手先位置誤差とする。

参考のため、従来の直接逆モデルングによって獲得した逆運動学モデルの出力を逆運動学解とする解法システムについても性能評価を行う。これを DIM (Direct Inverse Modeling) と略す。用いた神経回路は、入力層より順に、2, 15, 15, 3 個のニューロンによって構成されている。学習は 10 種類の初期状態から出発し、最も良いものを評価に用いる。

OFIM では、目標精度を 0.01 m とした場合、RMS 誤差は  $6.39 \times 10^{-3}$  m、初期値変更回数の平均値は 0.692 回であった。目標精度を 0.005 とした場合、RMS 誤差は  $5.48 \times 10^{-3}$  m、初期値変更回数の平均値は 4.29 回であった。DIM の RMS 誤差は  $1.62 \times 10^{-2}$  m であった。今回のシミュレーションでは、出力フィードバック型逆モデルは、DIM よりも高精度の逆運動学解を得ている。

## 5. む す び

本論文では、逆運動学問題の不良設定性を一部回避し、直接逆モデルングを用いて、人間の上肢逆運動学解法システムを学習する新たなモデルを提案し、シミュレーションによって、学習が可能であることを確認した。

直接逆モデルングには、生体モデルとして、もう一つの大きな弱点がある。学習時と制御時において、回路への入力信号の切換えが必要であるという弱点である。本論文の場合で言えば、上肢の制御時において、学習要素への入力信号は手先位置変化量の目標値であるが、学習時において、入力信号は視覚によって観測

された手先位置変化量である。随意によって生じる目標値信号と観測信号とは、最終的には一致すべきものであるが、信号の性質の隔たりは大きい。この弱点の解消は、今後の課題である。

**謝辞** 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に深謝致します。

## 文 献

- [1] M. I. Jordan, "Supervised Learning and Systems with Excess Degrees of Freedom," COINS Technical Report, 88-27, pp. 1-41, 1988.
- [2] M. Kuperstein, "Neural Model of Adaptive Hand-Eye Coordination for Single Postures," Sience, vol. 239, pp. 1308-1311, 1988.
- [3] 阪口 豊, 座間雅夫, 前田太郎, 中野 鑿, 大森隆司, "感覚系と運動系の協調システム(I)," 第 26 回計測自動制御学会大会予稿集, pp. 73-74, 1987.
- [4] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Internal Representation by Error Propagation," Parallel Distributed Processing, D. E. Rumelhart and J. L. McClelland and the PDP Research Group ed., pp. 318-326, MIT Press, 1986.
- [5] T. Kohonen, "Formation of topographic maps and columnar microstructures in nerve fields," Biological Cybernetics, 35, pp. 63-72, 1979.
- [6] M. Kawato, K. Furukawa, and R. Suzuki, "A Hierarchical Neural-network Model for Control and Learning of Voluntary Movement," Biol. Cybern., 57, pp. 169-185, 1987.
- [7] 横口正浩, 山崎興八洲, 笠井 健, "視覚系と運動系の 3 次元位置の対応付け(キャリブレーション機構)," 信学技報, MBE86-82, 1987.
- [8] 常本直貴, 館 晴, "視覚フィードバックを伴わない位置決めについて," 第 28 回計測制御学会学術講演会予稿集, pp. 39-40, 1989.
- [9] 前田太郎, 館 晴, "視覚性到達運動における両眼視と上肢位置感覚の統合," 計測自動制御学会論文集, vol. 32, no. 2, pp. 201-210, 1993.
- [10] 和田陽平, 大山 正, 今井省吾編, "感覚+知覚 心理学ハンドブック," pp. 250-253, 誠信書店, 1969.
- [11] 和田陽平, 大山 正, 今井省吾編, "感覚+知覚 心理学ハンドブック," pp. 637-638, 誠信書店, 1969.
- [12] M. Kawato, "A optimization and learning in Neural Networks for formation and control of coordinated movement," ATR Technical Report, TR-A-0086, 1990.
- [13] A. P. Georgopoulos, J. F. Kalaska, R. Caminiti, and J. T. Massey, "On the relations between the direction of two-dimensional arm movements and cell discharge in primate motor cortex," Journal of Neuroscience, 2, pp. 1527-1537, 1982.
- [14] A. P. Georgopoulos, J. F. Kalaska, M. D. Crutcher, R. Caminiti, and J. T. Massey, "The representation of movement direction in the motor cortex: Single cell and

- population studies," Dynamic aspects of neocortical function, G. M. Edelman, W. E. Gall, and W. M. Cowan ed., Neuro-sciences Research Foundation, pp. 501-524, 1984.
- [15] A. P. Georgopoulos, A. B. Schwartz, and R. E. Kettner, "Neuronal population coding of movement direction," Science, vol. 233, pp. 1416-1419, 1986.
- [16] M. A. Arbib and B. Hoff, "Trends in neural modeling for reach to grasp," Insights into the Reach to Grasp Movement, K. M. B. Bennett, and U. Castiello ed., North-Holland, pp. 311-344, 1994.
- [17] D. Bullock and S. Grossberg, "Neural Dynamics of Planned Arm Movements: Emergent Invariants and Speed-accuracy Properties during Trajectory Formation," Psychological Review, 95, pp. 49-90, 1988.
- [18] 大山英明, 館 瞳, "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, pp. 141-144, 1990.
- [19] 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), pp. 1434-1443, 1991.
- [20] 大山英明, 館 瞳, "非線形ゲインを学習する逆問題解法システム," 信学論(D-II), vol. J77-D-II, no. 7, pp. 1345-1354, July 1994.
- [21] D. E. Whitney, "Resolved motion rate control of manipulators and human prostheses," IEEE Trans. Man-Machine Syst., MMS-10, pp. 47-53, 1969.
- [22] 辻 敏夫, 伊藤宏司, 長町三生, 池本貴志, "筋運動制御系のインピーダンス調節機構と手先操作性," 計測自動制御学会論文集, vol. 24, no. 4, pp. 385-392, 1988.
- [23] S. I. Colombano, M. Compton, and M. Bualat, "Goal Directed Model Inversion," Proc. of International Joint Conference on Neural Networks (IJCNN '91 Singapore), pp. 2422-2427, 1991.
- [24] キスチャコフスカヤ著, 坂本市郎訳, "0歳児の運動の発達," pp. 82-133, 新読書社, 1974.
- [25] 楠原洋一, "赤ちゃんの体と心の発達 24カ月," pp. 14-47, 主婦の友社, 1993.

## 付 錄

### 1. 学習要素の学習

式(23), 式(24)より,

$$\Delta\theta^*(\Delta x, u)$$

$$=J^*(\theta)\Delta x + (I - J^*(\theta)J(\theta))(G(\theta)\Delta x + u) \quad (A \cdot 1)$$

を得る。 $J(\theta)$ がフルランクである場合、 $(I - J^*(\theta)J(\theta))$ のランクは  $m-n$  となる。 $m$  次元ベクトルの成分のうち  $n$  個の成分を適切に選んで、0としたベクトルを  $u^*$  とすると、任意の  $u$  に対して、次式を満たす  $u^*$  が存在する。

$$(I - J^*(\theta)J(\theta))(G(\theta)\Delta x + u) = (I - J^*(\theta)J(\theta))u^* \quad (A \cdot 2)$$

以下、 $J^*(\theta)$  を  $J^*$  と略す。ここで,

$$u^* = (u_1', u_2', \dots, u_{m-n}', 0, \dots, 0)^T \quad (A \cdot 3)$$

$$u' = (u_1', u_2', \dots, u_{m-n}')^T \quad (A \cdot 4)$$

とおいても一般性は失われない。 $u'$  と本文中の式(23)の  $\Delta\theta^*(\Delta x, u)$  の対応関係は 1 対 1 である。スケーリングを行っている式(27)においては、 $u'$  と  $v$  は同一視できる。よって,

$$\Phi(\theta, \Delta x) \doteq E(\Delta\theta^*(\Delta x, u))$$

$$= \frac{\int_U p(\Delta\theta^*(\Delta x, u)) \Delta\theta^*(\Delta x, u) du'}{\int_U p(\Delta\theta^*(\Delta x, u)) du'} \quad (A \cdot 5)$$

$$= J^* \Delta x + \frac{\int_U p(\Delta\theta^*)(I - J^* J) u^* du'}{\int_U p(\Delta\theta^*) du'} \quad (A \cdot 5)$$

と計算できる。ここで体積要素  $du'$  の積分領域  $U$  は、 $m-n$  次元のベクトル  $u'$  の全空間を表すものとする。すなわち,

$$\int_U h(v) du' = \int_{-\infty}^{\infty} \cdots \int_{-\infty}^{\infty} h(u') du_1' \cdots du_{m-n}' \quad (A \cdot 6)$$

である。

$\Delta\theta$  の分布が球対称の場合を考える。この場合、確率密度関数  $p(\Delta\theta)$  は原点からの距離の 2 乗  $\Delta\theta^T \Delta\theta$  の関数である。すなわち

$$p(\Delta\theta) = g(\Delta\theta^T \Delta\theta) \quad (A \cdot 7)$$

と書くことができる。

$$B = (I - J^* J) \quad (A \cdot 8)$$

とおくと,

$$J^{*T} B = 0 \quad (A \cdot 9)$$

より,

$$p(\Delta\theta^*) = g(\Delta x J^{*T} J^* \Delta x + u^{*T} B^T B u^*) \quad (A \cdot 10)$$

が成立する。 $p(\Delta\theta^*)$  は  $u'$  の各成分に対して、偶関数となり、奇関数となる  $Bu^*$  との積の積分値は 0 になる。よって,

$$\Phi(\theta, \Delta x) \doteq E(\Delta\theta^*) = J^* \Delta x \quad (A \cdot 11)$$

を得る。この場合、学習要素は本文中の式(12)の最小ノルム解を計算する。

本文中の式(31)に示すように、 $\Delta\theta$  の確率密度関数  $p(\Delta\theta)$  が、正定対称行列  $P$  とスカラ関数  $g(S)$  を利用して,

$$p(\Delta\theta) = g(\Delta\theta^T P^{-1} \Delta\theta) \quad (A \cdot 12)$$

と表される場合を考える。

$P$  は正定対称行列であるから、適当な行列  $R$  が存在し、

$$P = RR^T \quad (A \cdot 13)$$

と表せる。ここで、

$$\Delta\theta' = R^{-1}\Delta\theta$$

$$J' = JR$$

$$\Delta\theta'^* = J'^*\Delta x + (I - J'^*J'^T)u$$

$$J'^* = J'^T(J'J'^T)^{-1} \quad (A \cdot 14)$$

という変数変換を行えば、 $\Delta\theta$  の分布が球対称の場合の議論を利用でき、次式を得る。

$$\begin{aligned} \Phi(\theta, \dot{x}) &= E(\Delta\theta^*) \\ &= RE(\Delta\theta'^*) \\ &= RJ'^T(J'J'^T)^{-1}\Delta x \\ &= PJ^T(JPJ^T)^{-1}\Delta x \end{aligned} \quad (A \cdot 15)$$

## 2. 速度・加速度に着目した座標変換回路学習

関節角速度と手先速度の関係に着目して、座標変換回路を構成することが可能である。関節角速度指令を出力する神経回路の出力を  $\Phi(\theta, \dot{x})$  とする。 $\Phi(\theta, \dot{x})$  の教師信号を  $\Phi'(\theta, \dot{x})$  として、次のような教師信号を提案する。

$$\Phi'(\theta, \dot{x}) = \dot{\theta} \quad (A \cdot 16)$$

微小変位に着目した座標変換回路と同様にして、次式のような座標変換回路を得ることができる。

$$\dot{\theta} = \Phi(\theta, \dot{x}) = E(\dot{\theta}^*) = J^*(\theta)\dot{x} \quad (A \cdot 17)$$

これは、本文中の式(18)の逆モデルである。この学習要素に出力誤差のフィードバック項を含む目標手先位置速度

$$\dot{x}_d' = \dot{x}_d + K(x_d - x) \quad (A \cdot 18)$$

を入力することにより、目標手先軌道に追従する関節角速度ベクトルを計算できる。

速度の関係と同様に、加速度の関係に着目して、座標変換回路を構成することも可能である。

関節角加速度指令を出力する神経回路の出力  $\Phi(\theta, \dot{\theta}, \ddot{x})$  の教師信号  $\Phi'(\theta, \dot{\theta}, \ddot{x})$  を

$$\Phi'(\theta, \dot{\theta}, \ddot{x}) = \ddot{\theta} \quad (A \cdot 19)$$

とする。本文中の式(19)を満たす関節角加速度  $\ddot{\theta}^*$  は、

$$\begin{aligned} \ddot{\theta}^* &= J^*(\theta)(\ddot{x} - [\partial J(\theta)/\partial\theta]\dot{\theta}) \\ &\quad + (I - J^*(\theta)J(\theta))u \end{aligned} \quad (A \cdot 20)$$

であり、式(A・19)の学習によって、

$$\begin{aligned} \Phi(\theta, \dot{\theta}, \ddot{x}) &= E(\ddot{\theta}^*) \\ &= J^*(\theta)(\ddot{x} - [\partial J(\theta)/\partial\theta]\dot{\theta}) \end{aligned} \quad (A \cdot 21)$$

を得る。これは式(19)の逆モデルであり、手先位置加速度を関節角加速度に変換できる。 $K_D$  を適切なゲインと

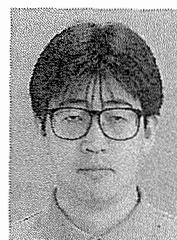
して、この回路に、出力誤差のフィードバック項を含む目標加速度

$$\dot{x}_d' = \dot{x}_d + K_D(\dot{x}_d - \dot{x}) + K(x_d - x) \quad (A \cdot 22)$$

を入力することにより、逆運動学問題を解くことが可能である。

(平成6年7月18日受付、7年2月23日再受付)

大山 英明 (正員)



昭60東大・工・航空卒。昭62同大大学院修士課程了。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課所属。人間の運動制御とそのモデル化、神経回路モデル、非線形最適化、テレイグジスタンスなどの研究に従事。計測自動制御学会、日本ロボット学会各会員。

前田 太郎 (正員)



昭62東大・工・計数卒。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課研究員。平4東大先端科学技術センター助手。平6東大工学部助手。人間の知覚特性のモデル化、神経回路網モデル、テレイグジスタンス、マン・マシンインタフェースの研究に従事。工博。平2計測自動制御学会論文賞、平4日本ロボット学会技術賞受賞。計測自動制御学会、日本ロボット学会各会員。

館 瞳



昭43東大・工・計数卒。昭48同大大学院工学系研究科博士課程了。工博。昭48より東京大学助手、通産省機械技術研究所研究員、同所主任研究官、遠隔制御課長、バイオロボティクス課長、東京大学助教授を経て、平4東京大学教授に就任、現在に至る。昭54～昭55米国マサチューセッツ工科大学(MIT)客員研究員。バイスペクトルを用いる信号処理、盲導犬ロボット、テレイグジスタンスなどの研究を行う。IEEE/EMBS学会賞、通商産業大臣賞、研究業務優秀者表彰などを受賞。IMEKO TC17(Robotics)議長、SICEフェロー。