

遺伝アルゴリズムによるロボットマニピュレータの モデル化誤差推定とその設定パラメータに関する一考察

清野 滋雄*・藤本 真作**・逢坂 一正**

*岡山理科大学大学院工学研究科機械工学専攻修士課程

**岡山理科大学工学部機械工学科

(1995年9月30日 受理)

1. はじめに

遺伝アルゴリズム (Genetic Algorithm : GA) は、学習・最適化問題に対する近似解法の一つであるということができ、近年この立場から、GA の制御問題への応用がいくつか報告されている¹⁾²⁾。それらの中で、逢坂ら¹⁾は GA をロボットマニピュレータのモデル化誤差推定へ応用している。これは、GA を実システムに適用する場合に生じる問題を回避し、与えられた目標軌道に対して高精度に追従できるようなモデル化誤差を GA を用いて推定するという方法で、比較的良好な推定結果を得ている。

しかしながら文献¹⁾は、GA の設定パラメータの決定方法について明確に記述されておらず、試行錯誤的に決定しているため、GA を工学的に利用するという観点からすれば不十分さが残されている。そこで、本論文では逢坂らの提案した GA を用いたロボットマニピュレータのモデル化誤差推定に、GA の設定パラメータの一決定手法を付加することによって設定パラメータの決定問題を解決し、同時に推定結果の改善を試みる。また、設定パラメータの決定手法についてその有効性を、計算機シミュレーションによって検証する。

2. 制御対象とモデル化誤差の記述

2.1 制御対象の記述

回転型関節を持つ n 自由度ロボットマニピュレータが制御対象であり、その動特性モデル $\langle P \rangle$ は、一般に次式のように表される。

$$M(\phi, \theta) \ddot{\theta} + h(\phi, \theta, \dot{\theta}) + g(\phi, \theta) = \tau \quad (1)$$

ここで、 $\theta \in R^n$ は関節角度ベクトル、 ϕ は適当な次元の物理パラメータベクトル、 $\tau \in R^n$ は駆動トルクベクトルであり、 $M(\phi, \theta) \in R^{n \times n}$ は慣性行列、 $h(\phi, \theta, \dot{\theta}) \in R^n$ は遠心力・コリオリ力・粘性摩擦力などを含む非線形トルクベクトル、 $g(\phi, \theta) \in R^n$ は重力ベクトルである。

このようなマニピュレータに対して、以下の仮定が満たされているものとする。

[仮定1] 変数 θ, τ は観測可能である。

[仮定2] 静止摩擦およびクーロン摩擦は1階微分可能な関数で近似できる。

[仮定3] 物理パラメータベクトル ϕ は有界で、その推定値 $\hat{\phi}$ が与えられている。

2.2 モデル化誤差の記述

前節で得られた動特性モデル(1)式と [仮定3] より、そのマニピュレータの公称値モデルは次式のように表すことができる。

$$M(\hat{\phi}, \theta)\ddot{\theta} + h(\hat{\phi}, \theta, \dot{\theta}) + g(\hat{\phi}, \theta) = \tau_L \quad (2)$$

ここで、 $\tau_L \in R^n$ は公称値モデルで得られる駆動トルクベクトルである。

(2)式の公称値モデルを利用して、図1に示すようにマニピュレータに対して非線形補償を行い、線形化モデル $\langle L \rangle$ を構築する。すなわち、駆動トルクベクトル τ_L は物理パラメータ $\hat{\phi}$ を用いて次式のように表される。

$$M_L(\hat{\phi}, \theta)u + f_L(\hat{\phi}, \theta, \dot{\theta}) = \tau_L \quad (3)$$

ここで、 $u \in R^n$ は制御入力ベクトル、 $M_L(\hat{\phi}, \theta) \in R^{n \times n}$ は非線形補償の際に用いる慣性行列、 $f_L(\hat{\phi}, \theta, \dot{\theta}) \in R^n$ は非線形補償ベクトルである。

また、入力を u 、出力を θ とする線形化モデル $\langle L \rangle$ は、(3)式における非線形補償の不完全さを考え、次式で表されるものを考える。

$$G_L(s) = \text{diag}[G_{L1}(s), G_{L2}(s), \dots, G_{Li}(s), \dots, G_{Ln}(s)] \quad (4)$$

ここで、

$$G_{Li}(s) = \frac{\gamma_i}{(s+\alpha_i)(s+\beta_i)} \quad (\text{リンク番号: } i=1, 2, \dots, n)$$

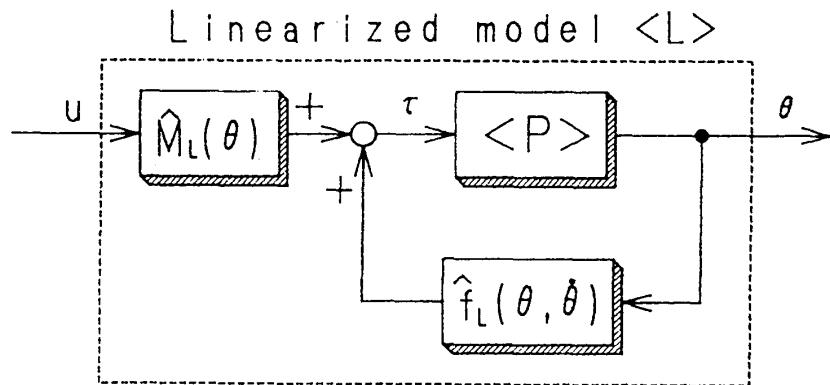


図1 線形化モデル

$\alpha_i, \beta_i, \gamma_i$ は正定数パラメータであり、線形化モデルが安定であることを要求している。

(3)式および(4)式より u を消去することで、次式の新しいモデルが生成できる。以降、このモデルを仮想公称値モデル $\langle \hat{P} \rangle$ と呼ぶ。

$$M_L(\hat{\phi}, \theta)(M_1 \ddot{\theta} + D_1 \dot{\theta} + K_1 \theta) + f_L(\hat{\phi}, \theta, \dot{\theta}) = \tau_L \quad (5)$$

ここで、 $M_1 = \text{diag}[1/\gamma_1, 1/\gamma_2, \dots, 1/\gamma_n]$, $D_1 = \text{diag}[(\alpha_1 + \beta_1)/\gamma_1, (\alpha_2 + \beta_2)/\gamma_2, \dots, (\alpha_n + \beta_n)/\gamma_n]$, $K_1 = \text{diag}[\alpha_1 \beta_1 / \gamma_1, \alpha_2 \beta_2 / \gamma_2, \dots, \alpha_n \beta_n / \gamma_n]$ である。

この仮想公称値モデルに対するモデル化誤差 $\Delta\tau$ を駆動トルクに基づき以下のように定義する。

$$\Delta\tau = \tau - \tau_L \quad (6)$$

ここで、 $\Delta\tau \in R^n$ はモデル化誤差ベクトルである。

このモデル化誤差ベクトルに対して、次の仮定が満たされているものとする。

[仮定 4] 目標軌道に対して本来のモデル化誤差 $\Delta\tau$ は、推定のときの GA の世代によって変化しない。

ここで、目標軌道（目標関節角度）は次の仮定を満たしているものとする。

[仮定 5] 目標関節角度ベクトル $\theta_d \in R^n$ は C^2 級の連続性を持っている。

3. モデル化誤差 $\Delta\tau$ の推定

遺伝アルゴリズムを用いたモデル化誤差の推定手順¹⁾は、図 2 に示すように大きく分けて過程 A の外乱推定オブザーバの過程と、過程 B の遺伝アルゴリズムの過程とから構成されている。

外乱推定オブザーバの過程（過程 A）では、逆モデル（仮想公称値モデルの逆モデル）を用いて推定が行われ、また、角度信号に対するフィルタリング操作が付加されている。本論文ではフィルタリング操作により生じる位相遅れを無駄時間要素と考えることにする。

一方、遺伝アルゴリズムの過程（過程 B）では、サンプリング時刻 t において目標軌道 $\theta_d(t)$ に追従するために必要な駆動トルク $\tau(t)$ を、遺伝アルゴリズムを用いて生成する。遺伝アルゴリズムの過程の内容は次のとおりである。

3.1 差分駆動トルク τ_s のコード化と初期集団

差分駆動トルク τ_s を w ビットの 2 進数遺伝子からなる個体にコード化する。

また、差分駆動トルク τ_s の初期集団はサンプリング時刻 t において、 N 個の差分角加速度 $\theta_s(t)$ をランダムに発生させ、 N 個の個体から構成される差分駆動トルク $\tau'_s(t)$ の初期集団を生成する。

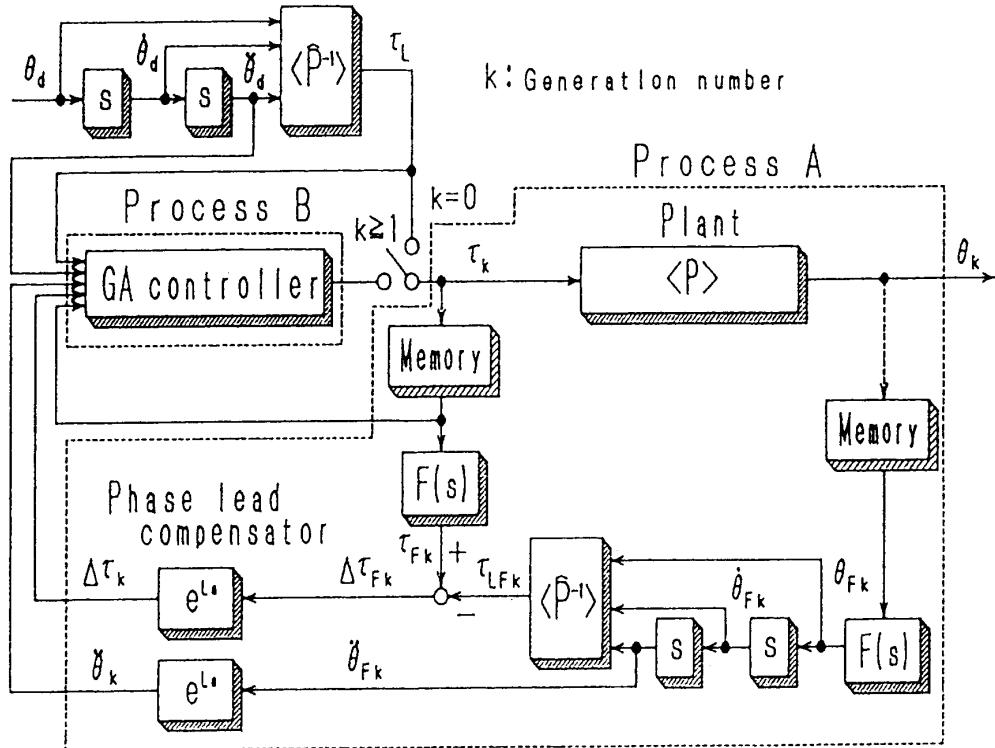


図2 制御系の構成

$$\tau'_s(t) = [\tau_s^1(t), \tau_s^2(t), \dots, \tau_s^m(t), \dots, \tau_s^N(t)]$$

ここで、 $\tau_s^m(t)$ はサンプリング時刻 t における m 番目の個体を表す。

3.2 解の評価

(1) 適応度関数について

適応度関数を次式で定義する。

$$J(t) = \exp[-e^\top(t) We(t)] \quad (7)$$

ただし、

$$\begin{aligned} e(t) &= \theta_{ds}(t) - \theta_s(t), & \theta_{ds}(t) &= \ddot{\theta}_d(t) - \ddot{\theta}_d(t - \Delta t) \\ \theta_s(t) &= \ddot{\theta}(t) - \ddot{\theta}(t - \Delta t), & W &= \text{diag}[W_1, W_2, \dots, W_n] \end{aligned}$$

とし、 $\theta_s(t) \in R^n$, $\theta_{ds}(t) \in R^n$ はそれぞれ差分された角加速度と差分された目標角加速度であり、以後、差分角加速度と差分目標角加速度と呼ぶこととし、 $W \in R^{n \times n}$ は定数重み行列である。

(2) 差分駆動トルク $\tau'_s(t)$ の再評価

シミュレーションによって適応度の再評価を行う。すなわち、 $k-1$ 世代目で推定された

モデル化誤差 $\Delta\tau_{k-1}$ を用いて疑似的な制御対象 $\tau_L + \Delta\tau_{k-1}$ を構築する。この制御対象に対してシミュレーションを行うことで適応度の最も高いと考えられる個体 $\tau_s^*(t)$ を求める。

3.3 遺伝操作

遺伝操作には次の方法を用いた。

[選択] 適応度比例戦略

[交叉] 交叉確率 P_c で単純交叉（1点交叉）

[突然変異] 突然変異確率 P_m で突然変異

4. 設定パラメータの決定手法

ここでは、遺伝アルゴリズムの設定パラメータの一決定手法について述べる。設定パラメータは誤差精度、収束速度などに大きな影響を与えるものと考えられる。そこで、以下の手法を用いることにより、3つのパラメータ、定数重み行列（適応度関数） W 、交叉確率 P_c 、突然変異確率 P_m を決定した。なお、パラメータの決定には、図3に示す2自由度マニピュレータを用いてシミュレーションを行った。

4.1 定数重み行列（適応度関数）について

GAは適応度が最大となる個体を確率的に探索するアルゴリズムであり、定数重み行列はその適応度の勾配を調節している。このことから、適応度の勾配はGAの誤差精度と収束速度に大きな影響を与えると考えられる。この理由として、まず、適応度の勾配が大きい場合は遺伝操作の後、集団のもつ一様性が大きくなり収束速度の向上が期待できるが、集団のもつ多様性が失われ局所解に陥る可能性が大きくなるため、誤差精度の改善が期待

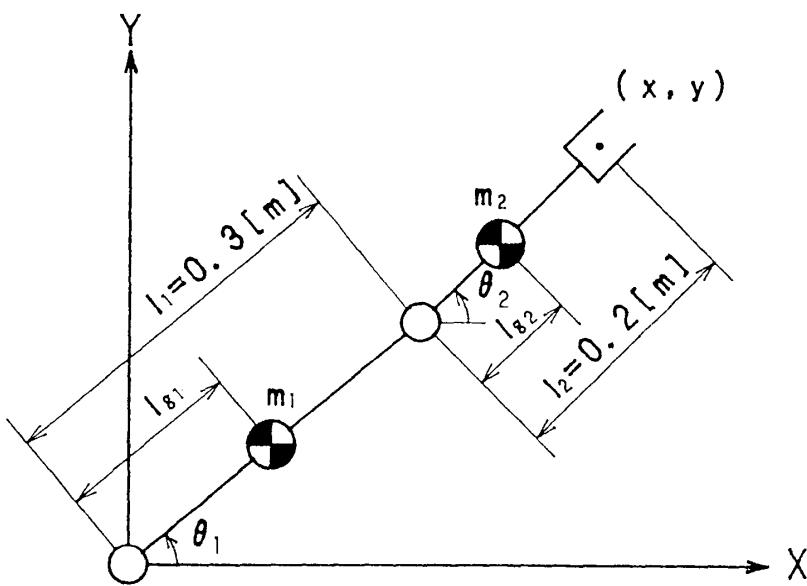


図3 2自由度マニピュレータ

できない。反対に、適応度の勾配が小さくなると、遺伝操作の後、集団のもつ多様性が大きくなり局所解に陥る可能性が小さくなるため、誤差精度の改善が期待できるが、集団のもつ一様性が小さくなり、収束速度の改善が期待できない。

以上のことから、適応度の勾配（定数重み行列）は、誤差精度、収束速度と密接に関係し、次に示す手法を用いることによってその値を決定することができる。すなわち、まず、 x 軸には、誤差精度の指標となり得ると考えられる(8)式を、また y 軸には定数重み(9)式を、そして、 z 軸には収束速度の指標になり得ると考えられる(10)式をそれぞれとり、これらの関係をシミュレーションによって調べる。得られた結果の一例を図 4 に示す。図 4 の結果より我々は、 k 世代目で得られた x 軸の値である最大角度誤差 e_{ki} と、 z 軸の値を計算することによって、定数重み行列 W の値を各世代毎に決定する。こうすることによって、各個体は適度に評価され、つまり、集団の一様性もしくは、多様性が適度に調節され、収束速度の改善が図れるものと期待される。

$$x = E_a[e_{(k-1)i}] \quad (8)$$

$$y = \log_{10}(W_i) \quad (9)$$

$$z = E_a[e_{ki}]/E_a[e_{(k-1)i}] \quad (10)$$

ただし、

W_i ：定数重み

$$\theta_{ski}(t) = \ddot{\theta}_{ki}(t) - \ddot{\theta}_{ki}(t - \Delta t)$$

$$\theta_{dski}(t) = \dot{\theta}_{dki}(t) - \dot{\theta}_{dki}(t - \Delta t)$$

$$e_{ki}(t) = \theta_{dski}(t) - \theta_{ski}(t)$$

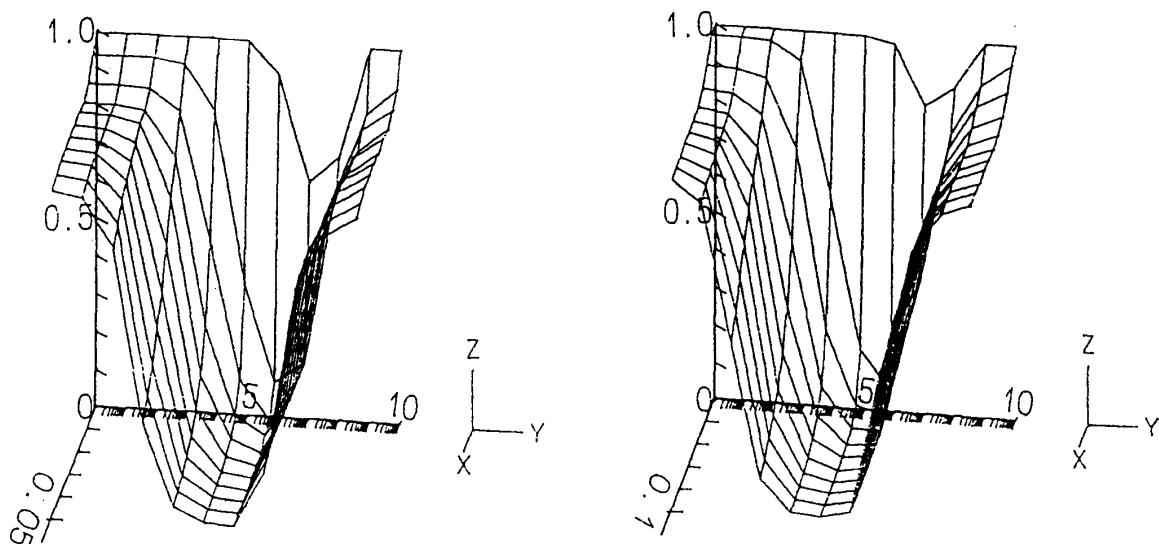


図 4 定数重み行列についての関係図

$E_a[(\cdot)] : (\cdot)$ の絶対値の平均値

i : マニピュレータのリンク番号, k : 世代数

である。

4.2 交叉確率と突然変異確率について

交叉確率（以降, P_c と呼ぶ）と突然変異確率（以降, P_m と呼ぶ）は次に示す関係から同時に両者を決定する。すなわち, P_c が比較的大きい場合には、遺伝操作の後、集団の多様性が失われるため局所解に陥る可能性が大きくなり、誤差精度の改善が期待できない。しかし、その反面小さい場合には、突然変異によりランダム・サーチ化してしまうため集団の一様性が失われ収束速度の改善に期待ができない。

一方、 P_m が比較的大きい場合には、遺伝操作の後、ランダム・サーチ化してしまうため集団の一様性が失われ収束速度の改善が期待できないが、小さい場合には、集団の多様性が失われるため局所解に陥る可能性が大きくなり、誤差精度の改善が期待できない。

これらの相反する関係から、 P_c , P_m を別々に決定するのではなく同時に決定する。すなわち、 P_c , P_m のそれぞれの値をある一定間隔ずつ変化させながらそれぞれの値の場合についてのシミュレーションを行い、その時の最大角度誤差が最小となるときの P_c と P_m の値を探査する。図5は得られた関係図であり、 x , y 軸にそれぞれ P_c , P_m , z 軸に最大角度誤差（4世代目における1, 2リンクの最大角度誤差の和）の逆数をとっている。また、 P_c については0.0から1.0まで0.1ごとに変化させ、 P_m については0.0から0.1まで0.01ごと

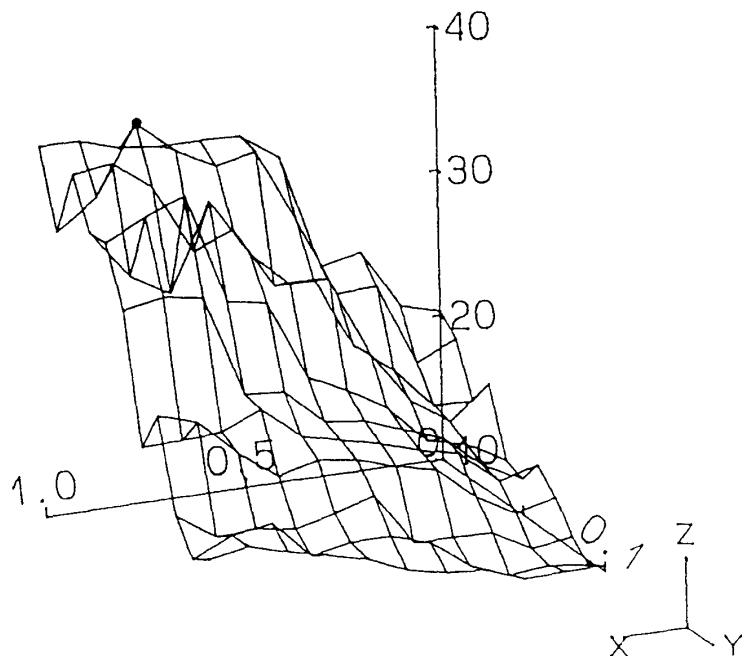


図5 交叉確率と突然変異確率についての関係図

に変化させている。得られた結果より、最大角度誤差が最小となる P_c , P_m は、それぞれ 0.80, 0.01 であった。ただし、図中の●点は最大角度誤差の最小値を示している。

5. シミュレーション結果

提案した手法を先の図 3 に示すような 2 自由度マニピュレータに適用し、計算機シミュレーションによってその有効性を検証する。

5.1 線形化モデルの同定

線形化モデルの同定は図 3 に示す 2 自由度マニピュレータを用いる。

フィルタは過程 B における差分角加速度 θ_s を考慮にいれ、カットオフ周波数 14 Hz の 3 次バターワースフィルタを用いた。また、このフィルタによって生じる無駄時間は 21 ms とした。ただし、サンプリング周期は 1 ms ($= \Delta t$) である。

線形化モデルの同定は、 $u(\ddot{\theta}_d)$ を入力、 θ を出力として、パラメータ α_i , β_i , γ_i を最小 2 乗法によって求める。同定結果を表 1 に示す。

5.2 遺伝アルゴリズムの設定パラメータ

過程 B の GA の設定パラメータの値を下の表 2 に示す。なお、個体のビット数を w 、個体数を N 、交叉確率を P_c 、突然変異確率を P_m 、定数重み行列を W 、世代数を k とする。また、i) は試行錯誤の場合であり、ii) は提案した手法の場合である。

5.3 シミュレーション結果

提案した手法の有効性を示すために、2 自由度マニピュレータに対して計算機シミュレーションを行った。

シミュレーションにおけるマニピュレータの動特性モデル $\langle P \rangle$ は、慣性モーメント I_1 , I_2 、質量中心 l_{g1} , l_{g2} を、それぞれ以下の $I_1 \triangleq 1.1 \times \hat{I}_1 \text{ kg} \cdot \text{m}^2$, $I_2 \triangleq 1.1 \times \hat{I}_2 \text{ kg} \cdot \text{m}^2$, $l_{g1} \triangleq$

表 1 線形化モデルのシステムパラメータ

i	α_1	β_1	γ_1
1	0.530	5.44×10^{-3}	0.994
2	0.522	5.91×10^{-3}	0.990

表 2 遺伝アルゴリズムの設定パラメータ

	i)	ii)										
w	12	12										
N	10	10										
P_c	0.85	0.80										
P_m	0.01	0.01										
W	diag [100, 80]	<table> <tr> <td>$k = 1$</td> <td>diag [50, 60]</td> </tr> <tr> <td>$k = 2$</td> <td>diag [80, 140]</td> </tr> <tr> <td>$k = 3$</td> <td>diag [120, 170]</td> </tr> <tr> <td>$k = 4$</td> <td>diag [150, 190]</td> </tr> <tr> <td>$k = 5$ 以降</td> <td>diag [400, 800]</td> </tr> </table>	$k = 1$	diag [50, 60]	$k = 2$	diag [80, 140]	$k = 3$	diag [120, 170]	$k = 4$	diag [150, 190]	$k = 5$ 以降	diag [400, 800]
$k = 1$	diag [50, 60]											
$k = 2$	diag [80, 140]											
$k = 3$	diag [120, 170]											
$k = 4$	diag [150, 190]											
$k = 5$ 以降	diag [400, 800]											

$\hat{l}_{g1} + 0.01 \text{ m}$, $\hat{l}_{g2} \Delta \hat{l}_{g2} + 0.01 \text{ m}$ とした。ただし, $\hat{I}_1 = 5.25 \times 10^{-1} \text{ kg} \cdot \text{m}^2$, $\hat{I}_2 = 2.3 \times 10^{-2} \text{ kg} \cdot \text{m}^2$, $\hat{l}_{g1} = 0 \text{ m}$, $\hat{l}_{g2} = 0 \text{ m}$ である。

シミュレーションでは重力補償を行わないものとする。また、目標関節角度³⁾は角加速度が時間のフーリエ展開で表される軌道を用いた。そして、シミュレーションのときの仮想出力信号に、白色雑音を付加することで、疑似的な出力信号 $\theta(t)$ を生成した。さらに、許容誤差 $\epsilon = [0.02, 0.02]^T \text{ rad}$ とした。以上の設定のもとに、計算機シミュレーションを行なった。

図6には、設定パラメータをそれぞれ提案した決定手法を用いて決定した場合と試行錯誤で決定した場合についての最大角度誤差の収束結果を示す。ここで、○は試行錯誤で決定した場合の収束結果を、●は提案した決定手法による場合の収束結果をそれぞれ示している。

図6では、提案した決定手法を用いた場合の方が試行錯誤により決定した場合と比較して良好な最大角度誤差の収束結果が得られていることが確認できる。また、双方の決定方法を比較すると、試行錯誤の場合、設計者が設定パラメータの特性を考慮に入れ、隨時、それらのパラメータ（この場合、6個のパラメータ）を決定しなければならず、その回数はときとして数十回にも及ぶため、設計者にかかる負担が非常に大きい。また、こうして得られたパラメータにおいても、それらの値を最適に設定できる保証がない。それに対し、提案した手法は、そのアルゴリズムを計算機によって自動化しているため、設計者の負担を軽減化するだけでなく、最適にそれらのパラメータを決定できる。

6. おわりに

遺伝アルゴリズムの工学への応用の立場から生じる設定パラメータの決定問題について

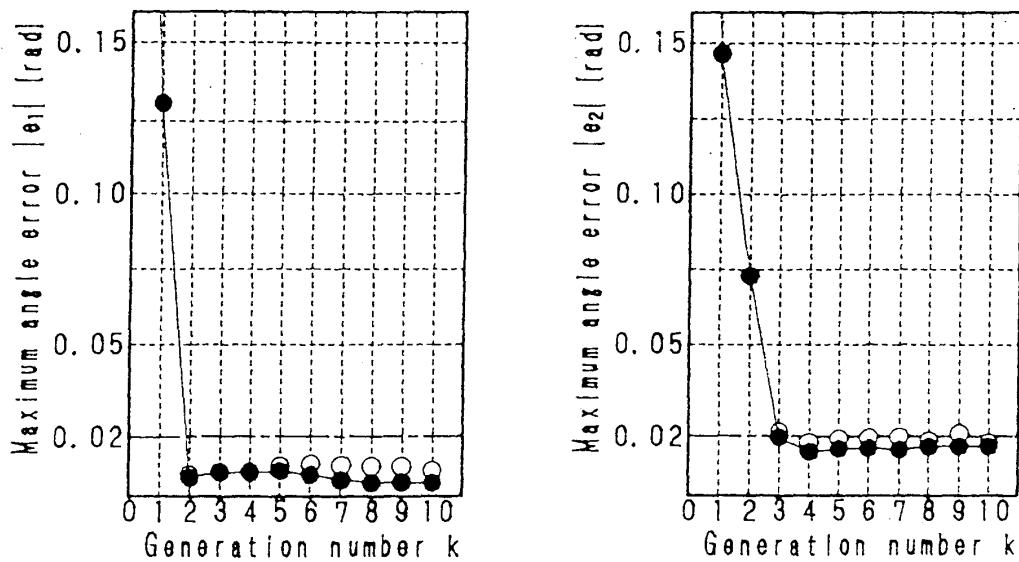


図6 最大角度誤差

その一決定手法を提案した。そして、その提案した手法を遺伝アルゴリズムを用いたロボットマニピュレータのモデル化誤差推定に適用し、その有効性について検証した。その結果、試行錯誤で決定された場合と比較して収束速度、誤差精度の面で改善されているのが確認された。また、提案した手法は、GA のパラメータ設定問題に対して、設計者の負担を軽減化するだけでなく、最適にそれらのパラメータを設定できる。以上のことから、われわれの提案する GA の設定パラメータの決定手法が有効であることが確認された。

参考文献

- 1) 藤本, 逢坂: 遺伝アルゴリズムを用いたロボットマニピュレータのモデル化誤差推定, 日本機械学会論文集, C編, 61-587, pp.3059—3068, (1995).
- 2) 横山, 立山, 三浦, 下山: 鉄棒ロボットの学習制御の研究, 日本機械学会 ROBOMECH '92講演論文集, B, pp.363—364, (1992).
- 3) 逢坂, 藤本, 小野: ロボットマニピュレータの高精度 PTP 制御のための軌道計画, 日本機械学会論文集, C編, 58-552, pp.2489—2494, (1992).

Estimation of the Modeling Errors for Robot Manipulators Using a Genetic Algorithm and a Setting of the Algorithm Parameters

Shigeo KIYONO*, Shinsaku FUJIMOTO** and Kazumasa OHSAKA**

*Graduate School of Science,

**Department of Mechanical Engineering,

Faculty of Engineering,

Okayama University of Science,

Ridai-cho 1-1, Okayama 700, Japan

(Received September 30, 1995)

In this paper, we propose a tuning method of parameters for genetic algorithm in an estimation algorithm of modeling errors. First, we explain compensating nonlinear terms that can be determined by a nominal model of a multi-degree-of-freedom manipulator. Then we construct a linearized model. The modeling errors are defined by difference of input torques between a real manipulator and the linearized model. Second, we explain an estimation algorithm of the modeling errors. It consists of the following two processes: one is disturbance obserber process (process A) using an inverse model of a nominal model and the other is genetic algorithm process (process B) using the results obtained by process A. Third, A problem of process B is a tuning method of parameters that are weight matrix of fitness function, crossover and mutation probabilities of a genetic algorithm. We propose a tuning method of these parameters using numerical simulations. Finally, the effectiveness of the proposed the tuning method of parameters is confirmed by numerical simulations of the 2-degree-of-freedom manipulator.