小口径トンネルロボットの
ニューラル形最適ゲインオートチューニング*青島伸一^{*1}, 武田幸喜^{*2}, 藪田哲郎^{*1}Autotuning of Feedback Gain using Neural Network
for a Small Tunnelling Robot

Shin'ichi AOSHIMA, Kouki TAKEDA and Tetsuro YABUTA

This paper describes the autotuning of feedback gain for a small tunnelling robot. We have already proposed a directional control method in that the head angle of the control input is the sum of the deviation multiplied by feedback gain K_p and the angular deviation multiplied by feedback gain K_a . In this paper, we use a neural network to obtain feedback gains K_p and K_a . The input of the neural network is the initial deviation and initial angular deviation. The output of the neural network is the feedback gains K_p and K_a . This neural network learns from deviation error. The optimum gains obtained by the proposed method agreed with the optimum gain obtained by trial and error. The neural network which can apply to any initial deviation was formed by using plural deviations. Moreover, this method can tune the optimum gains to any design line. These results showed the validity of this method.

Key Words: Tunnelling Robot, Directional Control, Autotuning, Feedback Gain, Neural Network, Learning, Deviation

1. はじめに

本小口径トンネルロボットは無排土式で押し込み推進させながらロボット先端のヘッド角を制御し、方向修正を行う。この方向制御は現状ではオペレータの経験と知識に頼っている。しかし、現在、施工品質の均一化、作業の効率化などの観点から方向制御の自動化が望まれている。そこで、われわれは、各種制御則を適用し、方向制御自動化の検討を行っており^{(1)~(5)}、計画線に対するロボット本体の位置偏差(以下偏差)とピッチング角度偏差(以下偏角)に、あるフィードバックゲインをかけたものを次の入力ヘッド角とするフィードバック制御則を適用した方向制御を既に提案し、その有効性を確認している⁽³⁾。最適フィードバックゲインは過渡応答の偏差絶対値積分値を評価基準とし、 K_p 、 K_a を変化させ探索し求めた。しかしこの方法では非常に多くの探索時間と手間を必要とした。そこで本報告では、自動的に最適フィードバックゲインを得ることができるニューラル形最適ゲインオートチューニング

法を提案し、その有効性をシミュレーションにより明らかにする。

2. システム構成

図1にトンネルロボットのシステム構成を示す。本システムはヘッド角修正機能を持つトンネルロボット本体、埋設管、埋設管を押し込む押管装置、油圧装置、操作盤よりなる。埋設管は押管装置により油圧で1本ずつ押し込まれる。このとき、オペレータはヘッド角を逐次修正し、計画線に沿うように方向制御を行う。ロボットのヘッドの直径は34 cm、埋設管の長さは約2.5 m、直径は32 cmである。

図1 トンネルロボットのシステム構成

* 平成3年6月7日 ロボティクス・メカトロニクス講演会において講演、原稿受付 平成3年7月25日。

^{*1} 正員、日本電信電話(株)フィールドシステム研究開発センター(〒319-11 茨城県那珂郡東海村白方白根162)。

^{*2} 日本電信電話(株)フィールドシステム研究開発センター。

3. ダイナミックモデル推定

図2で、本トンネルロボットのヘッド角とピッチング角について定義する。ヘッド角 $\theta_h(k)$ はロボット本体とヘッドのなす角であり、ピッチング角 $\theta_p(k)$ は計画線とロボット本体とのなす角、そして、ピッチング角変化量 $\Delta\theta_p(k)$ は1ストローク前と現在のピッチング角の差分である。トンネルロボットの施工データの分析により、現時刻のトンネルロボットの姿勢を近似的に表すピッチング角変化量の時系列項 $\{\Delta\theta_p(k), \Delta\theta_p(k-1), \dots, \Delta\theta_p(k-n)\}$ (n : モデルの次数) は、方向修正量 (ピッチング角変化量) $\Delta\theta_p(k)$ に大きな影響を与えることがわかった⁽²⁾ ので、この時系列項を含めたダイナミックモデルで方向修正量とヘッド角およびピッチング角変化量の時系列項との間の関係を表した⁽¹⁾。

生成したダイナミックモデルを式(1)に示す。このモデルは方向修正量がヘッド角とロボットの姿勢を近似的に表すピッチング角変化量の時系列項および確率分布項の和で表せる確率モデルで表した⁽²⁾。パラメータ a_n, b_n は最小二乗法によって推定される。以下に推定法を述べる。

式(2)は観測ベクトル値 $\{\Delta\theta_p(k), \{\theta_h(k)\}$ を式(1)に代入することによって得られる。評価関数 J は式(3)で表される。係数ベクトル $\mathbf{a}$ の最小二乗推定ベクトル $\mathbf{a}_e$ はこの評価関数 J を最小にする $\mathbf{a}$ となる。ベクトル $\mathbf{a}_e$ の右肩についている * は推定値であることを意味する。この推定係数ベクトル $\mathbf{a}_e$ は最小二乗法を適用することにより式(4)のように与えられる⁽⁶⁾。 $\mathbf{a}_e$ を決定するためのデータ数 na の最小数は $3n+1$ となる。

ダイナミックモデル

$$\begin{aligned} \Delta\theta_p(k) = & a_1\Delta\theta_p(k-1) + \dots + a_n\Delta\theta_p(k-n) \\ & + b_0\theta_h(k) + b_1\theta_h(k-1) + \dots \\ & + b_n\theta_h(k-n) + e(k) \end{aligned} \quad (1)$$

ここで、

$\Delta\theta_p(k-n)$: ピッチング角変化量

$\theta_h(k-n)$: ヘッド角

$e(k)$: 残差

n : モデルの次数

$$\Delta\theta_p = \mathbf{Z}\mathbf{a} + \mathbf{E} \quad (2)$$

$$J = [\Delta\theta_p - \mathbf{Z}\mathbf{a}]^T [\Delta\theta_p - \mathbf{Z}\mathbf{a}] \quad (3)$$

$$\mathbf{a}_e = [\mathbf{Z}^T \mathbf{Z}]^{-1} \mathbf{Z}^T \Delta\theta_p \quad (4)$$

ただし、

$$\mathbf{a} = [a_1, a_2, \dots, a_n, b_0, b_1, \dots, b_n]^T$$

$$\mathbf{a}_e = [a_1^*, a_2^*, \dots, a_n^*, b_0^*, b_1^*, \dots, b_n^*]^T$$

$$\Delta\theta_p = [\Delta\theta_p(n+1), \Delta\theta_p(n+2), \dots, \Delta\theta_p(na)]^T$$

$\mathbf{E}$: 誤差ベクトル

$$\mathbf{Z} = [\mathbf{Z}_1 \mathbf{Z}_2]$$

ここで、

$$\mathbf{Z}_1 = \begin{bmatrix} \Delta\theta_p(n) & \Delta\theta_p(n-1) & \dots & \Delta\theta_p(1) \\ \Delta\theta_p(n+1) & \Delta\theta_p(n) & \dots & \Delta\theta_p(2) \\ \vdots & \vdots & \ddots & \vdots \\ \Delta\theta_p(na-1) & \Delta\theta_p(na-2) & \dots & \Delta\theta_p(na-n) \end{bmatrix}$$

$$\mathbf{Z}_2 = \begin{bmatrix} \theta_h(n+1) & \theta_h(n) & \dots & \theta_h(1) \\ \theta_h(n+2) & \theta_h(n+1) & \dots & \theta_h(2) \\ \vdots & \vdots & \ddots & \vdots \\ \theta_h(na) & \theta_h(na-1) & \dots & \theta_h(na-n) \end{bmatrix}$$

表1に上記推定法を用いて推定された土質の異なる各地区のパラメータ推定値を示す。本報告におけるシミュレーションではこれらの値を用いている。土の種類は土、砂、ロームの3種類、 N 値は0~7の土質の各地区の実測データを使い、パラメータ推定を行った。 N 値は土質の硬さ、締まり具合を表す数値で、値が大きいほど硬い。また、 $N_0(m, \sigma)$ は平均値 m 、標準偏差 σ の正規分布を表している。

4. シミュレータ

図3でシミュレータで用いる各パラメータを定義する。下方の軌道が計画線であり、上方の軌道がロボットの軌道である。ストローク K における計画線の位置を $Y_d(k)$ 、計画線の傾きを $\theta_d(k)$ 、ロボットの位置を $Y(k)$ 、ロボットのピッチング角を $\theta_p(k)$ 、ピッチング

表1 土質の異なる各地区のパラメータ推定値

District	Soil	N value	a_1	a_2	a_3	b_0	b_1	b_2	b_3	$\sigma(k)$
Koshigaya	Clay	0	0.198	0.082	0.128	-0.056	0.144	-0.007	-0.066	No (0, 0.030)
Okayama	Clay	0~2	0.168	0.113	0.093	-0.043	0.120	-0.010	-0.023	No (0, 0.137)
Yokosuka	Clay	4~5	0.128	0.154	0.122	-0.080	0.166	-0.008	-0.048	No (0, 0.056)
Sayama	Loam	5	0.633	0.089	-0.030	0.160	-0.090	0.012	-0.053	No (0, 0.049)
Toussentou	Sand	5	0.735	-0.062	0.109	-0.006	0.053	0.035	-0.068	No (0, 0.055)
Zama 2	Loam	5~7	0.145	0.216	0.305	0.064	0.058	-0.040	-0.037	No (0, 0.059)
Zama 1	Loam	7	0.204	0.294	0.149	0.078	0.049	-0.096	-0.022	No (0, 0.084)

図2 ヘッド角とピッチング角変化量の定義

角変化量を $\Delta\theta_p(k)$ 、1 ストロークの長さを L 、残差を $e(k)$ 、モデルの次数を n とおく。

方向修正に関するシミュレータは前述したダイナミックモデル [式(1)] とロボットのピッチング角と位置の算出式 [式(5), (6)] によって構成される。方向制御のシミュレーションは以下のように行う。まず、式(7)で示すように、ある制御則を用いてヘッド角を求める。次にそのヘッド角を式(1)のダイナミックモデルに代入し、方向修正量を計算する。

シミュレータ

$$\begin{aligned}\Delta\theta_p(k) &= a_1\Delta\theta_p(k-1) + \dots + a_n\Delta\theta_p(k-n) \\ &+ b_0\theta_h(k) + b_1\theta_h(k-1) + \dots \\ &+ b_n\theta_h(k-n) + e(k) \dots\dots\dots (1)\end{aligned}$$

$$\theta_p(k) = \theta_p(k-1) + \Delta\theta_p(k) \dots\dots\dots (5)$$

$$Y(k) = Y(k-1) + L\sin\{\theta_p(k)\} \dots\dots\dots (6)$$

制御則

$$\theta_h(k) \leftarrow \text{制御則} \dots\dots\dots (7)$$

5. 方向制御法

本報告では、計画線に対するロボット本体の位置偏差とピッチング角偏差にゲインをかけたものを次の入力ヘッド角とするフィードバック制御則を用いた方向制御法を考案した。この制御則を式(8)に示す。 K_p は位置偏差フィードバックゲイン、 K_a はピッチング角度偏差フィードバックゲインである。図4に本方向制御のブロック線図を示す。

制御則

$$\begin{aligned}\theta_h(k) &= K_p\{Y_d(k) - Y(k-1)\} \\ &+ K_a\{\theta_a(k) - \theta_p(k-1)\} \dots\dots\dots (8)\end{aligned}$$

K_p : 位置偏差フィードバックゲイン deg/mm

K_a : ピッチング角度偏差フィードバックゲイン 無次元

シミュレータを用いてフィードバック方向制御法の有効性を検討した結果、位置偏差フィードバックゲインと角度偏差フィードバックゲインをうまく選択すれば、良好な方向制御を行うことがわかった⁽³⁾。そこで、著者らは前報で、過渡応答の偏差絶対値積分値を評価基準とし、試行錯誤的に K_p 、 K_a を変化させ最適フィードバックゲインを求めた。しかしこの方法では非常に多くの探索時間と手間を必要とした。

次章以下ではこのフィードバックゲイン最適値を自動的に得ることができる小口径トンネルロボットの最適ゲインオートチューニング法の検討を行う。

6. ニューラル形最適ゲインオートチューニング

最適ゲインオートチューニングに用いた、ニューラ

ルネットワーク構成図を図5に示す。入力層のユニット数は2個とし、入力層のユニットへは初期偏差と初期偏角を入力する。中間層のユニット数は8個に設定し、出力層のユニットは2個とし、フィードバックゲイン K_p 、 K_a を出力し、フィードバック制御則へ入力する。なお、本報告ではニューラルネットワークの学習に際して、以下に示すように結合係数、オフセット値の修正を行った⁽⁷⁾。

ニューラルネットの入力層と中間層の関係は以下の式で記述される。

$$U_j = \sum_i W_{ji} I_i + \theta_j \dots\dots\dots (9)$$

$$H_j = f(U_j) \dots\dots\dots (10)$$

$$f(U_j) = 1 / \{1 + \exp(-2U_j/U_0)\} \dots\dots\dots (11)$$

中間層と出力層との間の関係も同様に、以下のようになる。

$$S_k = \sum_j V_{kj} H_j + \gamma_k \dots\dots\dots (12)$$

図3 シミュレータで用いる各パラメータの定義

図4 フィードバック方向制御のブロック線図

図5 ニューラルネットワークの構成

$$O_k = f(S_k) \dots\dots\dots (13)$$

ニューラルネットの結合係数, オフセット値は学習により次のように修正する。

$$V_{kj} \rightarrow V_{kj} + m\Delta V_{kj} + a\delta_k H_j \dots\dots\dots (14)$$

$$\gamma_k \rightarrow \gamma_k + m\Delta \gamma_k + \beta \delta_k \dots\dots\dots (15)$$

$$W_{ji} \rightarrow W_{ji} + m\Delta W_{ji} + a\sigma_j I_i \dots\dots\dots (16)$$

$$\theta_j \rightarrow \theta_j + m\Delta \theta_j + \beta \sigma_j \dots\dots\dots (17)$$

また, 式(14)～(17)で用いられる δ_k , σ_j は次のように記述される。

$$\delta_k = (E_k / c_k) f'(S_k) \dots\dots\dots (18)$$

$$\sigma_j = f'(U_j) \sum_k \delta_k V_{kj} \dots\dots\dots (19)$$

ここで,

U_j : 中間層のユニット j の入力

S_k : 出力層のユニット k の入力

$f(\cdot)$: シグモイド関数

I_i : 入力層のユニット i の出力

H_j : 中間層のユニット j の出力

O_k : 出力層のユニット k の出力

(偏差ゲイン, 偏角ゲイン)

E_k : 偏差結合係数修正誤差

偏角結合係数修正誤差

c_k : 結合係数修正誤差に関する定数

W_{ji} : 入力層のユニット i から中間層のユニット j への結合係数

V_{kj} : 中間層のユニット j から出力層のユニット k への結合係数

θ_j : 中間層のユニット j のオフセット

γ_k : 出力層のユニット k のオフセット

ΔW_{ji} : 入力層のユニット i から中間層のユニット j への結合係数の 1 学習前の修正量

ΔV_{kj} : 中間層のユニット j から出力層のユニット k への結合係数の 1 学習前の修正量

$\Delta \theta_j$: 中間層のユニット j のオフセットの 1 学習前の修正量

$\Delta \gamma_k$: 出力層のユニット k のオフセットの 1 学習前の修正量

U_0 : シグモイド関数の傾きに関する定数

A : 結合係数の学習速度に関する定数

B : オフセット値の学習速度に関する定数

m : 修正時に用いられるモーメント値

フィードバックゲイン K_p , K_a の最適ゲインオートチューニングのフローチャート図を図 6 に示す。以下に, オートチューニングの具体的なプロセスを述べる。

(1) 初期設定として最小総偏差, 最小総偏角に任意のデータを入力しておく。

(2) 出力層より出力されたフィードバックゲインをフィードバック制御則のシミュレータに入れシミュレーションを行い, そのときの各ストローク時の計画線とロボット本体の偏差および, 偏角の総和を算出する。これを, 総偏差誤差, 総偏角誤差とする。

(3) 総偏差誤差と総偏角誤差を, 偏差結合係数修正誤差, 偏角結合係数修正誤差とする。ここで, 偏差結合係数修正誤差, 偏角結合係数修正誤差の値はこのままでは大きいため偏差結合係数修正誤差, 偏角結合係数修正誤差をそれぞれ誤差の大きさにあわせて設定した定数 c_k で割っている。また, シミュレーションの発散を避けるためシミュレーションの各結合係数修正量の最大値を設定した。

(4) 次に, 出力層より出力されたゲイン K_p , K_a に, 適当な値 α , β を加減算したゲインの組 $[(k_p + \alpha, k_a + \beta), (k_p + \alpha, k_a - \beta), (k_p - \alpha, k_a + \beta), (k_p - \alpha, k_a - \beta)]$ で小口径トンネルロボットのシミュレーションを 4 回行い, それらのゲインの組で最も総偏差誤差が小さくなる組のそれぞれの符号 [例えば $(k_p + \alpha, k_a - \beta)$ の場合は $+$ と $-$] を, プロセス(3)で求めた各結合係数修正誤差の符号としてつけ, あらためてそれらを偏差結合係数修正誤差, 偏角結合係数修正誤差 E_k とする。

次に, 逆伝ば学習則(バックプロパゲーション)を使って, 先ほど求めた偏差結合係数修正誤差, 偏角結合係数修正誤差によりニューラルネットワークの結合係数修正量を求め, 変更された結合係数による出力, すなわちゲイン K_p , K_a を出す。

図 6 最適ゲインオートチューニングのフローチャート図

ただし、4回のシミュレーション結果の総偏差誤差のいずれれもが出力層より出力されたゲイン K_p , K_a のシミュレーション結果である総偏差誤差より大きい場合は、偏差結合係数修正誤差および、偏角結合係数修正誤差はともに零とする。

(5) 前回の学習と今回の学習によって得られた各ゲインの差がある設定した値より連続して10回以上小さい値の場合、収束したとみなしそのときのゲイン値を最適ゲインとする。それまでの間は、(2)から(4)のプロセスを繰り返す。

ただし、プロセス実行中、ゲイン K_p , K_a が大きすぎ、ヘッド角が非常に大きくなって飽和したときには、ヘッド角の可動範囲が ± 1.5 度であるため総偏差誤差が一定になってほとんどゲインが修正されなくなるときがある。そのときはヘッド角が可動範囲 ± 1.5 度以内になるようにゲイン K_p , K_a を減少させる偏差結合係数修正誤差および偏角結合係数修正誤差を与えるようになっている。図7に、オートチューニングのブロック線図を示す。

次に、上述した学習方法で行ったオートチューニングの一例を以下に示す。ニューラルネットワークの入力層への入力および、小口径トンネルロボットの初期偏差は 50 mm、初期偏角は 0 deg とした。図8は、表1の狭山地区のダイナミックモデルのシミュレータを用いたもので、学習回数と、ニューラルネットワークより出力されるゲイン K_p , K_a および、出力されたゲインを使用したシミュレーションより計算される総偏差誤差との関係である。図を見ると、ニューラルネットワークの出力層より出力されるフィードバックゲイン K_p , K_a はかなり変動するが、総偏差誤差は確実に減少していることがわかる。また、学習回数が900回程度でゲインはほぼ安定し、学習回数を重ねてもあまり変化はなく収束したといえる。この場合のニューラルネットワークの各層の構成と各定数の値を以下に示す。

地区名 狭山地区

初期偏差 50 mm 初期偏角 0 deg

入力層 2 unit 中間層 8 unit 出力層 2 unit

シグモイドの傾きに関する定数 U_0 4.0

結合係数の学習速度に関する定数 A 0.2

オフセット値の学習速度に関する定数 B 0.1

モーメント値 m 0.75

また、図9(a)~(c)に初期偏差 50 mm、初期偏角 0 deg の狭山地区の学習中のシミュレーション結果を示す。これらの図より学習が進むほど良好な制御を行うゲインを出力していることがわかる。学習後の重み

図7 オートチューニングのブロック線図

図8 学習回数とゲインおよび総偏差誤差との関係

図9 学習中のシミュレーション結果(狭山)

図 10 学習後のシミュレーション結果 (狭山)

図 11 学習中のシミュレーション結果 (岡山)

図 12 学習後のシミュレーション結果 (岡山)

を使用したシミュレーション結果を図 10 に示す。図のように学習後には最適な制御を行うゲインを出力している。狭山地区の場合は学習前でも、シミュレーションで発散するようなゲインは出力していない。しかし、図 11(a)～(c)に岡山地区の学習中のシミュレーション結果を示すが、岡山地区の場合は学習前のゲインを用いた場合、シミュレーション結果は発散する。しかし、このような場合でも学習を行うにつれ良好な制御を行うゲインを出力していることがわかる。学習後の重みを使用したシミュレーション結果を図 12 に示す。

表 2 に、各地区で初期偏差 50 mm, 初期偏角 0 deg とした場合の、それぞれのゲインを小刻みに変化させて求めた最適ゲイン K_p , K_a および総偏差誤差と、本報告のニューラルネットワークによって求めた最適ゲイン K_p , K_a , および総偏差誤差を示す。ほぼ同じ値のゲインを出力していることがわかる。次に、初期偏角が零以外のシミュレーション結果を示す。ニューラルネットワークの入力層への入力値およびシミュレーションの初期設定値を初期偏差 50 mm, 初期偏角 1 deg とした狭山地区のゲインオートチューニングを行い、学習後の重みを用いたシミュレーションを行った結果を図 13 に示す。この場合も良好なチューニングを行っていることがわかる。

また、学習データ数を増やし、ニューラルネットワークへの入力層への入力および小口径トンネルロボットの初期偏差を 500 mm, 400 mm, 300 mm, 200 mm,

表 2 探索法と本方法による最適ゲインの比較

District	Kosiyu	Okayama	Yokosuka	Sayama	Tousentou	Zama 2	Zama 1
Trial and error	0.2	0.13	0.11	0.6	0.14	0.35	0.8
Optimum gain K_p	5.9	7.6	6.5	7.2	5.8	9.9	5.8
Trial and error	673.2	694.6	637.0	410.2	662.8	444.2	726.1
Optimum gain K_p	0.195	0.116	0.104	0.602	0.137	0.301	0.720
Neuro	6.347	6.433	5.521	6.737	5.213	8.639	5.464
Optimum gain K_a	637.6	700.9	618.7	393.7	604.2	425.9	624.7
Neuro							
Optimum gain K_a							
Integral deviation error

図 13 初期偏角が零以外の場合のシミュレーション結果

表 3 複数の初期偏差を用いて学習した場合の各初期偏差における最適ゲインと総偏差誤差

Initial deviation	500[mm]	400[mm]	300[mm]	200[mm]	100[mm]	50[mm]
Optimum gain K_p	0.20	0.24	0.28	0.34	0.42	0.46
Optimum gain K_a	8.30	8.01	7.71	7.43	7.16	7.04
Integral deviation error	10904.1	7800.50	5099.82	2853.29	1033.55	395.76

図 14 複数の初期偏差を用いて学習した場合のシミュレーション結果

100 mm, 50 mm とし初期偏角はすべて 0 deg としたゲインオートチューニングを行った。シミュレーション結果を図 14 に、ニューラルネットワークが出力した最適フィードバックゲイン K_p , K_a および総偏差誤差を表 3 に示す。図 14 を見ると、各初期偏差のシミュレーションは収束が速くかつ良好に計画線に追従しており、ニューラルネットワークは各初期偏差に適した最適フィードバックゲインを出力していることがわかる。この学習後のニューラルネットワークを使えば 500 mm 以内の任意の偏差に対応する最適ゲインを得ることができる。さらに、計画線が変化する場合のゲインチューニングを行った。図 15 にチューニング後のゲインを使ったシミュレーション結果を示す。地区は狭山で、初期偏差 50 mm, 初期偏角 -1 deg でチューニングした。図のように計画線が変化している場合でも良好な制御を行う最適ゲインを得ることができる。

以上述べたように、本報告で提案した方法により、小口径トンネルロボットのフィードバック方向制御の最適フィードバックゲインをチューニングできることを確認した。

7. お わ り に

本論文では、小口径トンネルロボットのフィードバック方向制御の最適フィードバックゲインを自動的にチューニングすることができるニューラル形最適ゲインオートチューニング法を提案し、実際の施工データから求めた方向修正量に関するダイナミックモデルを

図 15 計画線が変化している場合のシミュレーション結果

使ったシミュレータにより検討を行った。本方法では初期偏差と偏角を入力すると、その初期偏差、偏角で最も良好な方向制御を行う最適偏差、偏角フィードバックゲインを出力するニューラルネットワークを、シミュレーションから得られる総偏差偏角誤差を用い学習形成する。検討の結果、本手法により求めた最適ゲインは、過去に著者らが試行錯誤的に求めた最適ゲインとほぼ一致した。また、複数の初期偏差を使い学習させることにより、任意の初期偏差に対応する最適ゲインを出力するニューラルネットを形成することができた。さらに、計画線が変化している場合でも良好な制御を行う最適ゲインをチューニングできることを確認した。以上の結果より、本オートチューニング法の有効性が確認された。

最後に、本論文をまとめるにあたり、ご指導いただいた NTT(株)フィールドシステム研究開発センタ 涌井所長、光通信線路研究部 川瀬部長に感謝する。

文 献

- (1) 青島・藪田・武村, 小口径トンネルロボットのダイナミックモデル推定, 第 7 回ロボット学会講演会講演論文集, (1989-11), 715.
- (2) Aoshima, S. and Yabuta, T., Dynamic Model Identification and Control for a Small Diameter Tunneling Robot, Presented at 111th ASME Winter Annual Meeting, DSC-14D Symposium on Robotics, Nov. 25-30, DSC-Vol. 26 (1991), 187, Robotics Research.
- (3) 青島・藪田・武村, 小口径トンネルロボットの方向制御法と最適フィードバックゲイン, 日本機械学会第 68 期全国大会講演論文集 (1990-9), 89.
- (4) 青島・武田・藪田, 小口径トンネルロボットのファジィ方向制御, 第 8 回ロボット学会講演会講演論文集, (1990-11), 519.
- (5) 青島・武田・藪田, ニューラルネットワークを用いた小口径トンネルロボットの方向制御知識の獲得, 日本機械学会ロボティクス・メカトロニクス講演会講演論文集 (Vol. A), (1991-6), 339.
- (6) 相良・ほか 3 名, システム同定, (1983), 78, 計測自動制御学会.
- (7) 桐谷・ほか 7 名, 入門と実習ニューロコンピュータ, (1989), 38, 技術評論社.