

小口径推進工法における 方向制御自動化の取り組み

APPROACH TO AN AUTOMATED DIRECTIONAL CONTROL METHOD FOR A MICROTUNNELLING SYSTEM

○高塚 外志夫*¹ 青島 伸一*²
Toshio Takatsuka Shin-ichi Aoshima

【抄録】本論文では、先端ヘッドが傾動可能な小口径推進工法の方方向制御に関し、今後の需要増大に対応出来なくなる熟練オペレータに代わり、推進を高精度に行うことが出来る制御の自動化の取り組みを著したものである。まず、方向制御アルゴリズムを評価するダイナミック・シミュレータを構築し、位置偏差と角偏差に対するフィードバック制御則を適用した方向制御方法を提案し、更に操作性からの評価関数に基づき自動的に各偏差に対する最適フィードバックゲインをニューラルネットワークにより求める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した。

【Abstract】 This paper describes approach to an automated directional control method for a microtunnelling system in order to solve the problem of shortage of skilled operators. Firstly, we made a dynamic simulator to evaluate control laws, and proposed a directional feedback control method using a deviation and an angular deviation. Moreover, we proposed an autotuning method of optimum feedback gains using a neural network based on the cost function for the operational performances. Simulation results clarified the validity of this proposed method.

【キーワード】 推進、方向制御、フィードバック 制御、ニューラルネットワーク、ゲインオートチューニング

【Keywords】 Microtunnelling, Directional control, Feedback control, Neural network, Gain autotuning

1 はじめに

都市部における上下水道や電話等のライフライン施設の整備において、従来の開削工法では工事中の振動騒音あるいは交通障害等の住民生活環境への影響が問題視され、最近では非開削による小口径推進工法の採用が増えてきている。今後、小口径推進工法が更に発展・普及していくためには、施工精度の向上および工事の効率化・省力化を図る必要がある。特に、施工精度を確保するために方向修正を行うが、その判断は熟練オペレータの経験に頼っているのが現状で、今後の工事需要の拡大に熟練オペレータの養成が対応できなくなることが予想され、熟練を要しなくても高精度な推進工事が行える自動制御システムの開発が要望され

ている。⁽¹⁾

本論文では、先端ヘッドが傾動可能で複推進機構を有する小口径推進機械（以下エースモールと呼ぶ）の方向制御技術の課題および確立プロセスについて述べる。具体的には、方向制御における問題点、方向制御技術確立における取り組み方、方向制御則評価用ダイナミック・シミュレータの構築、フィードバック制御則、更にはニューラルネットワークを用いた最適ゲインの選定方法を示し、自動方向制御技術の可能性を明らかにする。

2 エースモールシステムの構成および 方向制御における問題点

*1 日本電信電話株式会社 フィールドシステム研究開発センタ 主幹研究員
*2 同 上 主任研究員

図1にエースモール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もつ先端装置、推進管、押し管装置、油圧装置および操作盤よりなる。長距離推進を可能とするため先端抵抗を先端装置のジャッキに管周面抵抗を押し管装置のジャッキに分担して対応する複推進方式を採用している。先端装置のジャッキストロークは45cmである。また垂直方向の姿勢・位置はピッチング計、液圧計で、水平方向の姿勢・位置は折れ角計、電磁法により計測している。⁽²⁾

先端装置の方向制御は図2に示すように先端ヘッドを強制的に傾動させて先端装置を追従させる方法を採用している。なお、傾動量は最大 1.5° である。この場合、首振り動作や周辺地盤との相互作用により制御に対する応答が複雑である。図3はある施工現場（ローム土質）における制御量（ヘッド角）と先端装置の姿勢角変化（ピッチング角変化量）の関係を示したものである。制御量を変化させた場合と制御量を保持した場合に分けてあるが、それぞれに於いて方向修正量は制御量が同じでもかなりばらついており、制御量が異なるとそのばらつきかたも異なっている。これは過去の軌跡の影響が制御量（ヘッド角）と方向修正量（ピッチング角変化量）の間に強い影響を及ぼしており、エースモールの運動（ダイナミクス）を考慮する必要があることを示している。このため、エースモールの運動を無視して、その時点での偏差とヘッド角の情報のみで方向修正を行うのは難しい。

熟練オペレータは、先端装置が辿ってきた軌跡および制御の効き具合を総合的に判断し方向修正を実行するため比較的良好に計画線形に沿わせる事ができる。方向修正のコンピュータコントロール化を目指す時、以上のような要因を考慮する必要がある。

3 自動方向制御技術確立への取り組み方

本研究の最終目標は、ロバストなコンピュータコントロール可能な方向制御則を求めることにある。しかし、直接的に最終目標に到達するために、制御則を直ちに実機にインプリメントして評価することは施工上でトラブルの発生可能性があるため難しい。このため、方向制御則確立の前段階として、制御則を評価・調整するためのダイナミックシミュレータの確立が必要である。したがって、まず施工データからエースモールの運動方程式を同程し、その結果を基にシミュレータを作成する。次にこのダイナミックシミュレータを用いて方向制御則の評価および制御パラメータ調整を行う。図4に示すように評価およびパラメータ調整が終了した段階で実機に制御則をインプリメントすることになる。

次に制御則のロバスト性について議論する。制御技




図1 エースモールのシステム構成






図2 方向制御の機構



(a)制御量を変化させた場合



(b)制御量を保持した場合

図3 制御量と姿勢角変化の関係

術は過去から数多い理論が提案され、最近ではファジイ制御のシールド工事への適用もみられる。⁽³⁾ 制御理論の分野では様々な機能を実現する各種制御則が提案されているが、これらの制御則を実際に応用するに際しては、ロバスト性が非常に重要になる。ロバスト性とはどのような環境状態においても安定な制御性能を実現できることであり、この性能はシステムの非線形性および外乱等と密接に関連するため、なかなか理論的に解明できない分野である。このため、ロバスト性の判断は主に使用実績に依存することになる。制御則としては実績のあるPID 制御則、現代制御理論に立脚した最適制御則、最近のファジイ制御則およびニューロ制御則等があるが、実績の観点から考慮するとPID 制御則およびファジイ制御則が考えられる。ファジイ制御則の構造はオペレータの知識から構成されるものでオペレータの経験および実績が反映されていると考えられる。

本論文では具体的な応用を目指して制御則のなかで最も実績のあるPID 制御則をとりあげ、偏差および地盤のN値に対応した最適フィードバックゲインの決定をニューラルネットワーク（以下NNと呼ぶ）の最適化機能を用いたオートチューニング法を用いた結果を示す。

4 エースモールのシステム同程とダイナミックシミュレータの構築

2章の議論で示したように、エースモールの姿勢角変化（ピッチング角変化量）は制御量（ヘッド角）のみならず、過去の軌跡にも密接に関係するので、これらの関係を記述する数学モデルを施工データから同程する。この得られた数学モデルはエースモールの運動方程式を表しており、この結果を用いてダイナミックシミュレータが構築できる。

まず最初に、数学モデルに用いるパラメータの定義を行う。図5に示すようにヘッド角 $\theta_h(k)$ は先端装置本体とヘッドのなす角であり、ピッチング角 $\theta_p(k)$ は計画線と先端装置本体のなす角、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。

エースモールの運動方程式は、式(1)に示すように方向修正量に関連するヘッド角と過去の軌跡に関連するピッチング角変化量の時系項および確率分布項の線形モデル構造を採用した。⁽⁴⁾ パラメータ a_n b_n は施工データから最小二乗法によって推定されるもので、以下に推定法を示す。

施工データから得られる観測ベクトル値 $\{\Delta\theta_p(k)\}$ 、 $\{\theta_h(k)\}$ は式(1)の関係式を用いて式(2)の形で記述できる。この時、評価関数 J は式(3)に示す誤差 E の




図4 自動方向制御技術確立への取り組み方




図5 ヘッド角とピッチング角変化量の定義

2次形式を用いる。係数ベクトル α の最小二乗推定ベクトル $\hat{\alpha}$ はこの評価関数 J を最小にする α となる。ベクトル α 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 $\hat{\alpha}$ 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。 $\hat{\alpha}$ を決定するためのデータ数 n の最小数は $3n+1$ となる。

ダイナミックモデル

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

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

$$\Delta\theta_p = Z\alpha + E \quad \dots (2)$$

$$J = [\Delta\theta_p - Z\alpha]^T [\Delta\theta_p - Z\alpha] \quad \dots (3)$$

$$\hat{\alpha} = [Z^T Z]^{-1} Z^T \Delta\theta_p \quad \dots (4)$$

ただし、

$$\alpha = [a_1, a_2, \dots, a_n, b_0, b_1, \dots, b_n]^T$$

$$\alpha_e = [a'_1, a'_2, \dots, a'_n, b'_0, b'_1, \dots, b'_n]^T$$

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

E : 誤差ベクトル

$$Z = [Z_1 \ Z_2]$$

ここで、

$$Z1 = \begin{bmatrix} \Delta\theta_p(n) & \Delta\theta_p(n-1) & \cdots & \Delta\theta_p(1) \\ \Delta\theta_p(n+1) & \Delta\theta_p(n) & \cdots & \Delta\theta_p(2) \\ \vdots & \vdots & \ddots & \vdots \\ \Delta\theta_p(na-1) & \Delta\theta_p(na-2) & \cdots & \Delta\theta_p(na-n) \end{bmatrix}$$
$$Z2 = \begin{bmatrix} \theta_h(n+1) & \theta_h(n) & \cdots & \theta_h(1) \\ \theta_h(n+2) & \theta_h(n+1) & \cdots & \theta_h(2) \\ \vdots & \vdots & \ddots & \vdots \\ \theta_h(na) & \theta_h(na-1) & \cdots & \theta_h(na-n) \end{bmatrix}$$

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。本論文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。土の種類は普通土、砂質土、ローム土の3種類、N値は0～7の各地区での実測データを使い、パラメータ推定を行った。また、 N_0 (m , σ) は平均値 m 、標準偏差 σ の正規分布を表している。

エースモールの運動方程式を求めることができたので、この結果を用いてダイナミックシミュレータを構築する。図6にシミュレータで用いる各パラメータを定義する。下方の線が計画線であり、上方の線がエースモールの軌道である。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 $\theta_d(k)$ 、エースモールの位置を $Y(k)$ 、ピッチング角を $\theta_p(k)$ 、その変化量を $\Delta\theta_p(k)$ 、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)〕とエースモール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。方向制御シミュレーションは以下に行う。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。

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	$e(k)$
C1	Clay	0	0.198	0.062	0.128	-0.056	0.144	-0.007	-0.066	No (0,0.030)
C2	Clay	0-2	0.168	0.113	0.093	-0.043	0.120	-0.010	-0.023	No (0,0.137)
C3	Clay	4-5	0.128	0.154	0.122	-0.080	0.166	-0.008	-0.048	No (0,0.056)
L1	Loam	5	0.633	0.089	-0.030	0.160	-0.090	0.012	-0.053	No (0,0.049)
S1	Sand	5	0.735	-0.052	0.109	-0.006	0.053	0.035	-0.068	No (0,0.055)
L2	Loam	5-7	0.145	0.216	0.305	0.064	0.058	-0.040	-0.037	No (0,0.059)
L3	Loam	7	0.204	0.294	0.149	0.078	0.049	-0.096	-0.022	No (0,0.084)

シミュレータ

$$\Delta\theta_p(k) = a_1 \Delta\theta_p(k-1) + \cdots + a_n \Delta\theta_p(k-n) + b_0 \theta_h(k) + b_1 \theta_h(k-1) + \cdots + b_n \theta_h(k-n) + e(k) \quad (1)$$
$$\theta_p(k) = \theta_p(k-1) + \Delta\theta_p(k) \quad (5)$$
$$Y(k) = Y(k-1) + L \sin \{ \theta_p(k) \} \quad (6)$$

制御則

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

5 フィードバック方向制御則

4章までに、エースモールの運動を模擬するシミュレータが構築できたので、本シミュレータを用いて制御則の評価を行う。制御則はシミュレータに記述されている式(7)に適用することにより、エースモールの運動として評価できる。

制御則は各種提案されているが、具体的な応用を考慮してロバスト性の観点から最も使用実績のあるPID制御則を採用した。制御則の構造は式(7)に示すものであり、エースモール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制御量（ヘッド角）とする制御則を考案した。⁽⁵⁾ 制御則を式(7)に示す。

K_p は位置偏差の、 K_a はピッチング角偏差のフィードバックゲインであり、図7に本方向制御のブロック線図を示す。

制御則

$$\theta_h(k) = K_p [Y_d(k) - Y(k-1)] + K_a [\theta_d(k) - \theta_p(k-1)] \quad (7)$$




図6 シミュレータで用いるパラメータの定義




図7 フィードバック制御のブロック線図

以下にフィードバック制御則の制御機能を評価するために、表1で示したC2地区のパラメータ推定値を用いたシミュレーション結果を示す。計画線はすべて初期位置、角度とも零の水平線とした。図8(a)は制御則式(7)で角度偏差フィードバックゲイン $K_a = 0$ （無次元）としたもので、角度偏差量を使わない場合のシミュレーション結果である。ただし、位置偏差フィードバックゲイン $K_p = 0.01 \text{ deg/mm}$ とし、残差 $e(k)$ は平均値 0 deg 、標準偏差 0.13 deg の正規分布で近似した。初期偏差、角度それぞれ 500 mm , 0 deg とした。

位置偏差フィードバックのみでは安定化できないことがわかる。しかし、位置偏差、角度偏差フィードバックの両方を用いると安定化が可能となる。図8(b)～(d)は両方を使った場合である。図8(b)は $K_p = 0.01$, $K_a = 0.5$ とし、図8(c)は $K_p = 0.01$, $K_a = 2$ および図8(d)は $K_p = 0.01$, $K_a = 4$ とした。その他の条件は図8(a)の場合と同じである。角度偏差フィードバックを入れると、図8(b)では収束するが振動が残る。また、図8(d)では収束するが整定時間がかかる。これらに対して図8(c)では素早く収束することがわかる。

このようにシミュレータを用いて方向制御則の有効性を検討した結果、位置偏差および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。

また、それぞれのゲインの中でも目標値からの偏差等を最小にする最適ゲインが存在する。一例としてN値が0～2であるC2地区のデータを使って最適ゲインの説明をする。図9に $K_p = 0.01 \text{ deg/mm}$ と固定したときの、 K_a —過度応答の偏差絶対値積分値特性を示す。偏差絶対値積分値特性とは、初期値から目標値に追従するまでの偏差絶対値を積分したものである。ただし、残差 $e(k)$ は平均値 0 deg 、標準偏差 0.13 deg の正規分布で近似し、初期位置、角度はそれぞれ、 500 mm , 0 deg とした。また、計画線は初期値 0 mm の水平線とした。この図より、偏差絶対値積分値が最小になる K_a を求めることができる。この場合、 $K_a = 1.5$ となる。次に上記と同様に K_p を 0.01 から 10 deg/mm まで変化させて偏差絶対値積分値が最小になる K_a を求める。これらの結果を用いると、図10に示す K_p —最小偏差絶対値積分値特性が求まる。これより偏差絶対値積分値が最小になる K_p は 0.07 deg/mm となり、その時の K_a は K_a —過度応答の偏差絶対値積分値特性により 7.8 （無次元）と求まる。このように試行錯誤をかせねながら最適ゲインを求める。図11にこの最適な K_a , K_p を使った場合の方向制御シミュレーション結果を示す。初期位置は 500 mm 、計画線は位置が 0 mm の水平線とした。図に示されるように良好な制御が行われていることがわかる。




図8 方向制御シミュレーション結果




図9 K_a 過度応答の偏差絶対値積分値特性
[$K_p = 0.01 \text{ deg/mm}$ 固定]

6 ニューラル型最適ゲインオートチューニング

前章で、過渡応答の偏差絶対値積分値を評価基準とし、試行錯誤的に最適フィードバックゲインを求めたが、非常に多くの探索時間と手間が必要であった。この探索プロセスは、評価関数を最小にする最適化問題を人間が試行錯誤で行うことに相当しており、従来から制御系におけるシンセシスとして扱われた問題である。しかし、NNの最適化機能を用いることにより、評価関数を最小にする最適ゲインを自動的に求めることができる。すなわち、試行錯誤のプロセスをNNの学習機能に依存させることにより、最適ゲインをオートチューニングすることができる。⁽⁶⁾

最適ゲインオートチューニングに用いたNN構成図を図12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位置偏差と角偏差を入力する。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。NNの学習ブロック線図を図13に示す。この図に示すように、NNはステップ応答の積分誤差を最小にするような学習を進める。図14にNNの学習フローチャートを示す。学習アルゴリズムはバックプロパゲーションを基本として、⁽⁷⁾ 学習の係数の符号については、図14に示すように探索方法を用いた。

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。NNの入力層への入力である初期位置偏差・角偏差は50mm、0degとした。図15はL1地区を対象にしたNNの学習過程を示す。この図は学習回数とNNより出力されるゲイン K_a 、 K_p およびそのゲインを用いたシミュレーションにより計算される総偏差誤差との関係である。図を見ると、NNの出力層より出力されるフィードバックゲイン K_p は学習初期にはかなり変動するが、総偏差誤差は確実に現象していることがわかる。また、学習回数が900回程度でゲインは安定し、学習を重ねてもあまり変化はなく、収束したといえる。学習後の重みを使用したシミュレーション結果を図16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。

表2に初期位置偏差、角偏差が50mm、0degの場合の試行錯誤で用いた提案型最適ゲインとNNによって求めた最適ゲインの比較を示す。両者はほぼ一致しており、さらに、NNによる場合の方が総偏差誤差を小さくでき、より最適値に近いことがわかる。このようにNNの最適化機能を用いることにより最適ゲインのオートチューニングが可能になることがわかる。

7 最適ゲイン設計のための評価関数設定法

前章までの最適ゲイン設計のための評価関数の設定




図10 K_p 最小偏差絶対値積分特性




図11 最適ゲインを用いた
方向制御シミュレーション結果




図12 ニューラルネットワークの構成

表2 探索法の違いによる最適ゲインの比較

District	C1	C2	C3	L1	S1	L2	L3
Trial and error Optimum gain K_p	0.2	0.13	0.11	0.6	0.14	0.35	0.8
Trial and error Optimum gain K_a	5.9	7.6	6.5	7.2	5.8	9.9	5.8
Integral deviation error	673.2	694.6	637.0	410.2	662.8	444.2	726.1
Neuro Optimum gain K_p	0.195	0.116	0.104	0.602	0.137	0.301	0.720
Neuro Optimum gain K_a	6.347	6.433	5.521	6.737	5.213	8.639	5.464
Integral deviation error	637.6	700.9	618.7	393.7	604.2	425.9	624.7

方法は、目標値からの位置偏差の絶対値積分値を使っていた（以下評価法1と呼ぶ）。このように位置偏差を主眼とした評価関数を用いた場合は、図17に示すよ




図13 ニューラルネットワークの学習ブロック線図




図14 最適ゲインオートチューニングのフロー図

表3 評価関数の違いによる最適ゲインの比較

	Optimum gain K_p	Optimum gain K_a	Integral Deviation error
Evaluation-1	0.119	6.67	698.2
Evaluation-2	0.047	3.15	959.3




図15 学習回数とゲイン および総偏差誤差の関係




図16 学習後の最適ゲインを用いた 方向制御シミュレーション結果




図17 評価法1による最適ゲインを用いた 方向制御シミュレーション結果




図18 評価法2による最適ゲインを用いた 方向制御シミュレーション結果

うに大きいヘッド角(制御量)変化を頻繁に行うことになる。このような制御方法はバング・バング制御と呼び、実際の工事では現実的な方法とは言えない。実際の工事を考慮すれば、現実には則した評価関数を設定する必要がある。そこで、式(8)のレギュレータ型の評価関数を設定した。この評価関数は、角偏差と制御量であるヘッド角を抑制するものである(以下評価法2と呼ぶ)。

評価関数

$$J = \sum \{ q_D e(k)^2 + q_A \theta_s(k)^2 + r \theta_h(k)^2 \} \quad \dots (8)$$

ただし、

$e(k)$: 目標値からの位置偏差

$\theta_s(k)$: 目標角からの角偏差

$\theta_h(k)$: ヘッド角(制御量)

q_D, q_A, r : 重みゲイン

前記と同様に、C2地区のモデルを使い、初期位置偏差を50mm、角偏差を0degとし、重みゲインは

$q_D : q_A : r = 1 : 100 : 100$ の条件で最適ゲイン探索を行った。

表3に評価法1と評価法2の最適フィードバックゲインおよび総偏差誤差(比較のために偏差絶対値積分のみ)を示す。最適フィードバックゲインは評価法1に比べ評価法2の方が小さなヘッド角を出力するため小さくなり、そのため総偏差誤差は大きくなっている。図18に最適フィードバックゲインを使用したときのシミュレーション結果である各ストローク時のヘッド角を示す。一定の初期偏差に対する収束のスピードは評価法2の方が遅くはなるが、ヘッド角は比較的小さめに抑えられており、熟練オペレータの操作に近いものと判断できる。本章ではレギュレータ型の評価関数を例にとって議論したが、この他現実的な評価関数設定法の条件としては、オーバシュートを抑制する条件、制御量であるヘッド角変更回数を少なくする条件等があり、今後の評価関数設定の検討課題といえる。

7 おわりに

本論文では方向制御技術に関する問題点および自動方向制御技術確立に際しての取り組み方を整理した。この整理結果を基にロバスト性の観点からPID型フィードバック制御則を取上げ、具体的なフィードバック制御則並びに操作性に基づく評価関数により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型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に関するダイナミックモデルを使ったシミュレータにより可能性を明らかにしてきた。本方法では初期位置偏差、角偏差に対しても良好な方向制御を行う最適位置偏差、角偏差フィ

ードバックゲインをNNの最適化機能を用いて学習形成する。ニューラル型オートチューニング法によるものは人間が試行錯誤的に求めた最適ゲインとはほぼ一致しており、その最適ゲインを用いたシミュレーションにおいても熟練オペレータの操作に近い結果が得られている。本論文ではNNの最適化機能に注目して議論してきたが、NNは写像型の知識としての情報圧縮機能も有している。このため図19に示すNNの学習プロセスにおいて、初期偏差を変えた場合についても並行して学習させると、各種初期偏差に対応した最適ゲインを出力するニューラル型知識モジュールとして扱うことができる。さらに、N値の変動に対しては、各N値に対応して学習させたニューラル型知識モジュールを用意しておくことによって対応することができる。

今後は、最適ゲインの評価に現場における操作性を更に反映させたもの、あるいは制御則にファジィ制御を用いた検討を進め、実機にインプリメントして実工事における評価を行いつつ、推進工法の方角制御の自動化を実現していきたい。

最後に、本論文をまとめるにあたり、ご指導頂いた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、藪田主幹研究員および高度非開削プロジェクト木村部長に感謝します。

参考文献

- (1) 杉山、高津、"小口径管推進工法の高度化に関する研究" 月刊推進技術、Vol. 6, NO. 2, pp. 53-61(1992)
- (2) 野村、保科、塩見、梅津、"方向制御可能なトンネル機械の設計と特性" 土木学会論文集、NO. 358, pp. 61-68(1985)
- (3) 桑原、原田、背野、竹内、"ファジィ理論のシールド掘進制御への適用" 土木学会論文集、NO. 391, pp. 169-177(1988)
- (4) S. Aoshima & T. Yabuta, "Simplified Dynamic Model for Amount of Directional Correction of Small-Diameter Tunneling Robot" ASME Journal of Dynamic Systems, Measurement and Control, Vol. 114, pp. 476-480(1992)
- (5) 青島、武田、藪田、"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" 日本機械学会論文集、Vol. 58, NO. 546, pp. 492-498(1992)
- (6) 青島、武田、藪田、"小口径トンネルロボットのニューラル型最適ゲインオートチューニング" 日本機械学会論文集、Vol. 58, NO. 546, pp. 499-505(1992)
- (7) 桐谷他7名、"入門と実習ニューロコンピュータ" 技術評論社、pp. 38(1989)