

## 第5章

# ニューラルネットワーク による運動制御

### 5.1 はじめに

海中ロボットの運動は、一般的に流体中における6自由度の運動となる上に、非線形な流体力や運動モード間の相互干渉を考慮しなければならない。更に、ミッションに応じた搭載機器の変更や潮流に代表される環境の変化などが考えられる。これらの海中ロボットに特有な条件を踏まえると、海中ロボットの運動制御システムは、状況に応じて柔軟に対処できる適応的なシステムであることが望ましい。

以上の観点から、海中ロボットの運動制御システムとして、Yoergerらはロバストな制御手法であるSliding Mode Control[100]を適用し、非線形なダイナミクスを直接扱っている。文献[102]においてシミュレーションにおいて、海中ロボットの運動方程式のパラメータを変化させた場合の挙動を比較しており、モデル誤差の存在に対しても良好な制御結果が得られることを示している。ニューラルネットワークを海中ロボットに適用した例は、Yuhによる強化学習法を用いてコントローラを調整する手法[71,72]や、藤井らが提案している自己生成型ニューラルネットコントローラシステム（以後、SONCS: Self-Organizing Neural-net Controller Systemと呼ぶ）がある[63~65,105]。Yuhの手法は、Fig. 5-1aに示すように制御誤差を適応的に代入し直接コントローラを調整する手法であり、対象とするシステムの動特性に関する詳しい情報を必要としない。一方、藤井らの手法は、Fig. 5-1bに示すように、対象とするシステムの動特性を有する運動モデルを構築し、運動モデルを介して間接的に調整する手法である。つまり、上記の手法の違いは、コントローラの調整量を制御結果から直接的に算出するか、誤差逆伝播法の特徴を利用し、運動モデルの結合荷重を用いて間接的に算出するかである。

SONCSは、予め制御対象の運動特性が数学的な形で表現されていないという条件のもとで、何らかの方法で対象の運動特性を把握しながら目的に応じて適応的にコントローラを生成するシステムとして提案され、以下のような4つのサブシステムから構成されている。

- ・ 未熟なコントローラ
- ・ 制御対象とフォワードモデルに対して制御信号を生成するコントローラネットワーク
- ・ 制御対象の動特性を表現するフォワードモデル
- ・ フォワードモデルの出力に基づいて制御結果を評価し、コントローラを調整する評価調整機構

基本的な考えは、フォワードモデルとコントローラネットワークを1つの大きなネットワークと見なし、誤差逆伝播法に基づいてコントローラを調整するというものである。つまり、フォワードモデルから出力される状態量を評価し、得られ



た評価値をフォワードモデルを介してコントローラネットワークに逆伝播し、コントローラの結合荷重のみを調整する手法である。既に、航行型海中ロボットのテストベッドであるPW45を用いた定深度航行や航行型海中ロボットのプロトタイプであるPTEROA150を用いた定高度航行、ダイナミックダンパへの適用等、実験やシミュレーションを通じて良好な結果を得ている[63~70]。しかしながら、従来のコントローラ調整法によって満足できるコントローラを得るには、ある一定時間の実航行により実験データをサンプリングし、そこから得られた時系列データの評価からコントローラを調整する、というプロセスを反復して行うことが必要であった。つまり、一回のコントローラ調整毎にある一定時間の実験データが必要とされる。そのため、精度の良いコントローラを得るまでにかなりの時間を要するという問題が存在した。

本章では、上記の問題点を踏まえ、第3章で述べたIdentification Networkのシミュレーション機能を利用した高速なコントローラ生成法「Imaginary Training」及びSONCSをベースとして開発した新たなコントロールシステムの並列処理構造について述べる[103,104]。

## 5. 2 コントローラ生成法「Imaginary Training」

### 5. 2. 1 並列処理構造

Fig. 5-1bに示したSONCSでは、フォワードモデルの入力として制御対象からの状態量を入力値として用いているため、制御対象をコントロールする機構とコントローラを調整する機構を同期して動作させる必要がある。これは、単一プロセッサによる逐次的な処理を前提とした構造であるため、データのサンプリング周期などによりコントローラの調整速度に限界があり、適切なコントローラを得るためには多くの時間を要する等の問題が存在する。そこで、Identification Networkのシミュレーション機能を利用することにより、コントローラの調整機構と制御対象の制御機構を分離することを考える。つまり、Identification Networkは制御信号の時系列入力に対して、状態量の時系列を出力するネットワークであり、制御対象の運動を代替して表現することが可能となる。従って、得られた運動モデルが十分な精度で制御対象を表現することができれば、実時間での制御対象のコントロールとは独立して、非同期にコントローラを調整するシステムが実現できる。

本章では、並列処理を前提としたFig. 5-2に示す新たな構造のコントローラシステムについて述べる。以後、他のシステムと区別するためITNN (Imaginary Training system with Neural Network) と表記する。ITNNは、大きく分けると実時間に基づいて処理が行なわれる(a)Real-World Part と、実時間とは独立してプロセッサの処理能力に依存して処理が行われる(b)Imaginary-World Partの2つの独立した部分から構成される。

(a) Real-World Partはフィードバック制御システムであり、制御対象とそのコントローラ ( $C_R$ ) から成る。コントローラ  $C_R$  への入力には制御目標値  $r(t)$  と制御対象から得られる状態量  $Se(t)$  との差であり、制御対象への操作量  $u(t)$  を出力し、実時間に基づいて処理を行う機構である。

(b) Imaginary-World Partは、コントローラ調整機構と運動の同定機構からなる。コントローラ  $C_I$  は、コントローラ  $C_R$  と同じ構造とし、制御目標値  $r(t)$  と運動モデルから得られる状態量  $Sf(t)$  との差の入力に対して、操作量  $u(t)$  を出力する。運動モデルには Identification Network を用いている。従って、入力はコントローラ  $C_I$  からの操作量  $u(t)$  の時系列と状態量の初期値  $Sf(0)$  であり、出力は一時間ステップ後の状態量  $Sf(t+\Delta t)$  である。得られた状態量  $Sf$  の時系列を評価し、誤差逆伝播法を用いてコントローラの調整を行う。この調整法を「Imaginary Training」と呼び、次節において詳しく述べる。同定機構では、運動特性の変化に対処するため、制御対象から得られるサンプリングデータを教示データとして、運動モデルに追加学習を行ない、随時運動モデルの更新を行う。

ITNN は、実時間でのオペレーションとコントローラ調整及び運動同定の処理を分離した並列処理構造を採用し、各処理プロセス間の処理を非同期で行えるように考案したシステムである。従って、これらの処理プロセスを並列に実行することにより、オンラインでのコントローラ調整及び運動モデルの更新を効率的に行うことが可能である。

### 5. 2. 2 オンラインコントローラ生成法「Imaginary Training」

ITNN のコントローラ調整は、運動制御の評価となる一連の状態量を制御結果として評価し、コントローラと運動モデルを一つのネットワークと考えて、評価値から計算される誤差信号をコントローラに逆伝播して結合加重を修正することにより行われる。

本論文で提案する ITNN では、Fig. 5-3 の概念図に示すように、制御対象は実世界、つまり Real-World Part において航行しており、それと並行して自身の頭 (コンピュータ) 内の Imaginary-World Part において別途様々な運動をシミュレーションすることを念頭に置いたシステムである。そのシミュレーションデータを用いて、コントローラを調整することにより、実世界とは無関係に目標に適したコントローラを得ることが可能となる。即ち、Imaginary-World Part ではデータサンプリングによる処理の中断が存在せず、Real-World Part と Imaginary-World Part の 2 つの部分に対応する処理を並列に実行することにより、コントローラの調整が高速化される。このコントローラ調整手法を Imaginary Training と呼ぶ。

$C_I$ ,  $C_R$ 、運動モデルが調整されていない初期状態からのコントローラの生成過程は以下の通りである。始めに、Imaginary Training を効率よく実行するため、オフラインで各ネットワークの初期化を行う。簡単なルールからなる制御則を用



いて実験を行い、航行データを教示データとして学習することによりコントローラC\_I及びC\_Rを初期化する。同様に、ある一定時間の航行データをもとに運動モデルを生成する。その後、初期化された各ネットワークを用いて運動制御のシミュレーションを行い、得られた状態量と操作量の一連の時系列データをコントローラC\_Iの性能評価とし、(5.1)式に示される評価関数 $E_c$ に基づいてコントローラC\_Iを調整する。

$$E_c = 1/2 \sum_k \{ (r(k) - Sf(k))^T \cdot A \cdot (r(k) - Sf(k)) \} \quad (5.1)$$

ここで、 $r(t)$ は目標信号、 $A$ は正定数の重み行列であり、添字の $k$ は時間を表す。コントローラC\_Iがある一定回数調整された後、コントローラC\_Iの結合加重でReal-World PartのコントローラC\_Rの結合加重を更新する。

更新されたコントローラC\_Rを用いた制御対象のコントロールと並行して、運動モデルをオンラインで修正し、得られた運動モデルを用いてコントローラの再調整を行うことにより、制御対象の動特性の変化に対しても適応することができる。

## 5. 4 海中ロボットへの適用

制御対象として航行型海中ロボットのテストベッドPW45、汎用テストベッドTwin-Burger、長期観測用ロボットR-one Robotを取り挙げ、先に述べたコントローラ生成法「Imaginary Training」を適用し、その有効性の検討を行う。ここでは第3章において提案した Identification Network を運動モデルとして導入している。

### 5. 4. 1 PW45の縦運動制御

PW45の縦運動を制御するためのネットワーク構造を Fig. 5-4 に示す。コントローラの入力変数は、ピッチ角  $\theta$ 、ピッチ角速度  $\Delta\theta$ 、深度  $D$ 、深度変化  $\Delta D$  及び1時間ステップ前のエレベータ切り角  $\delta_e$  とした。中間層のニューロン数は5であり、出力はエレベータ切り角  $\delta_e$  である。運動モデルは、第3章と同様、入力変数としてピッチ角  $\theta$ 、深度  $D$ 、及びエレベータ切り角  $\delta_e$  を扱い、第3層においてピッチ角速度  $\Delta\theta$ 、及び深度変化  $\Delta D$  を出力する構造とした。中間層のニューロン数は5である。積分層においてピッチ角  $\theta$  及び深度  $D$  を出力した後、回帰的結合 RC\_1 を介して、得られた状態量はコントローラの入力層及び運動モデルの出力層に送信し、運動のシミュレーションを行う。

ITNN において運動制御システムを構築する場合、最初に何らかの手法を用いてロボットの制御を行い、運動モデル及び初期コントローラを作成する必要がある。ここでは、初期コントローラの教示データとして、適当なゲインを用いた線形フィードバック制御を用いてPW45の縦運動の制御した実験結果を用いる。目標ピッチ角速度 = 0.0 [rad/sec]、及び目標深度 = 1.0 [m] ( $=D_p$ ) とした。

初期のコントローラによる実験結果及び運動モデルの出力を Fig. 5-5 に示す。初期のコントローラは、エレベータを激しくトリムさせており、それにともなうピッチ角及び深度において激しい振動が生じている。運動モデルはエレベータ切り角を 0.5Hz で変化させたときの同定モデルを初期値として用い、追加学習を行なって作成した。PW45の縦運動を良く表現できている。

初期のコントローラをもとにして、(5.2) 式の評価関数を用いてコントローラの調整を行った。

$$Ec = 1/2 \sum_k \{ (\Delta\theta(k) - \Delta\theta_r(k))^2 + (D(k) - D_r(k))^2 \} \quad (5.2)$$

シミュレーションによってコントローラの調整が行われる様子を Fig. 5-6 に示す。30秒間の航行の度にコントローラの調整を行っている。左から順に、1回、3回、10回の調整後のシミュレーション結果であり、上からエレベータ切り角  $\delta_e$ 、ピッチ角速度  $\Delta\theta$ 、深度  $D$  となっている。ここでは、運動モデルの更新は行っていない。3回の調整により、深度に関して若干の偏差が存在するものの、ピッチ角速度の振動が収まっている。10回の調整後のシミュレーションでは、ピッチ角速度及び深度とも良好に制御されており、Imaginary Training によりコントローラ



の調整が行えている様子が、Fig. 5-7 に示された評価値の推移からも分かる。

得られたコントローラを用いて、実際に実機を航行させた結果がFig. 5-8の実験結果である。実験においても、ピッチ角速度及び深度に関して良好に制御されている。従来のSONCSにおける手法では、一回の調整毎に実際に一定時間ロボットを航行させ、得られたコントローラの調整を行っていたが、本論文で提案するコントローラ調整法 Imaginary Training を用いることにより、実際にロボットを航行させなくとも調整が行なうことが可能となる。これらの結果から航行型海中ロボットの制御システムとして十分に機能しており、提案した調整法が有効であることが分かる。

#### 5. 4. 2 Twin-Burger の方位角制御

海中ロボット Twin-Burger の方位角制御問題に対して本手法を適用し、提案する手法が非航行型のロボットに対しても有効であるか検討を行なう。

コントローラ調整機構、つまり Imaginary-World Part のネットワーク構造をFig. 5-9に示す。コントローラは、制御目標値  $(\psi(t), \Delta\psi(t))$  と運動モデルの出力から得られる状態量  $(\psi(t), \Delta\psi(t))$  の差と、自身の出力から得られる一時間ステップ前の操作量  $u(t-\Delta t)$  の入力に対し、操作量  $u(t)$  を出力する。運動モデルはコントローラからの操作量入力  $u(t)$  に対し、第3層において方位角角速度  $\Delta\psi(t)$  を出力する。

コントローラの初期化は、Fig. 5-10 に示す関数に基づいて行った。Fig. 5-10 の制御則からなるコントローラ及びそれにより初期化されたコントローラ C\_R による実験結果をFig. 5-11に示す。初期状態の C\_R では、目標角の近傍で振動を起こしており、艇の向きを目標角に一致させることができていない。適切なコントローラを得るため、(5.3) 式の評価関数に基づき Imaginary Training を行い、C\_I の調整を行う。

$$Ec = 1/2 \sum_k \{ (\psi(k) - \psi_r(k))^2 + (\Delta\psi(k) - \Delta\psi_r(k))^2 \} \quad (5.3)$$

Imaginary Training における初期条件として  $\psi(t) = 0.5$  [rad]、 $\Delta\psi(t) = 0.0$  [rad/sec] を与えた。20秒間にわたる制御とそれに基づく C\_I の修正を1回の調整とし、合計2000回のコントローラ調整を行った。Imaginary Training における運動モデルの出力をFig. 5-12に示す。太線は調整後のコントローラ C\_I によって運動モデルを制御した場合のシミュレーション結果であり、細線は初期のコントローラ C\_I によるシミュレーション結果である。Imaginary-World Part のコントローラ C\_I は、Imaginary Training により目標値を満たすよう調整されている。評価関数値の推移を表したものがFig. 5-13であり、約1000~1500回のコントローラ調整で評価値が収束していることが分かる。

Imaginary Training により調整されたコントローラ C\_I の結合加重を用いて、Real-World Part のコントローラ C\_R の結合加重の更新を行う。更新されたコント

ローラ C\_R による実験結果を Figs. 5-14, 5-15 に示す。Fig. 5-14 は、約 8 秒と 12 秒において艇に外乱を与えた場合の実験結果である。角速度の変化に瞬時に反応して、目標角及び目標角速度を維持している。Fig. 5-15 は、初期条件を  $\psi(0) \approx 0.5$  [rad] として行った場合の実験結果である。約 5 秒間で目標角及び目標角速度に達しており、良好に制御が行われている。実験においても、Imaginary-World Part の運動モデルの制御結果と同様な結果が得られており、Identification Network を用いた運動モデルが Twin-Burger の Yawing 運動に関して良く表現できていることを示している。

以上の実験結果から、非航行型の海中ロボットの運動に関しても、本論で提案した手法により目標関数に適合したコントローラの生成が行えることが分かる。

#### 5. 4. 3 R-one Robot の方位角制御

海中ロボット R-one robot の水面における方位角運動に関して、同様のコントローラ調整法を用いてコントローラを調整した。その場合のネットワーク構造を Fig. 5-16 に示す。コントローラへの入力は、Twin-Burger の方位角制御問題と同じく、制御目標値 ( $\psi_r(k)$ ,  $\Delta\psi_r(k)$ ) と運動モデルの出力から得られる状態量 ( $\psi(k)$ ,  $\Delta\psi(k)$ ) の差と、自身の出力から得られる一時間ステップ前のラダー切り角  $r(k-\Delta k)$  及びスラスト指令値の入力に対し、ラダー切り角  $r(k)$  を出力する。運動モデルはコントローラからの入力  $r(k)$  及びスラスト指令値に対し、第 3 層において方位角速度  $\Delta\psi^2(k)$  を出力する。ここでは、シミュレーションにおいて Fig. 5-17 に示すように操作量に外乱を加えた場合のコントローラの挙動について検討する。目標方位角は 30 度とし、Imaginary Training における評価式は Twin-Burger の方位角制御において用いたものと同じである。

スラスト指令値が 150 の場合のシミュレーション結果を Figs. 5-18~20 に示す。Fig. 5-18 は外乱を加えていない状態での制御結果であり、約 50 秒で目標の 30 度に達しており、オーバーシュートも存在せず、良好な結果が得られている。定常状態にある 50 秒後以降において、操作量であるラダー指令値  $r(k)$  にオフセットが存在する。これは運動モデルを作成した教示データにおいて、トレンドが存在することを意味している。Fig. 5-19 は一定外乱を加えた場合の制御結果であり、Fig. 5-18 と比較すると外乱に相当するラダー切り角の変化が見られる。長周期の外乱に対して良好に振舞えることが分かる。Fig. 5-20 は外乱を正弦波状に変化させた場合の制御結果である。角速度に振動が見られるものの、良好に制御が行えている。Table 5-1 に外乱に対するコントローラ調整の評価値をまとめる。外乱の有無に係わらず、評価値はほぼ同じ値を示しており、本論文で採用しているコントローラが外乱に対しても有効に挙動することが分かる。



## 5. 5 考察

本章では、Identification Networkを運動モデルとして導入したコントロールシステム ITNN (Imaginary Training system with Neural Network) とそのコントローラ生成法 Imaginary Trainingを提案し、シミュレーションを通じてオフラインでコントローラ生成を行い、具体的な海中ロボットに適用した。ITNNは、並列処理を念頭におき考案したシステムであり、実時間に基づいて稼働する Real-World Part とプロセッサの能力に依存して処理が行われる Imaginary-World Part から構成される。各々の処理は、非同期の通信を行ないながら、独立して処理されるためコントローラの調整及び運動の同定を効率よく行なうことができる。ITNNを海中ロボットに適用した実験結果では、評価関数に基づいたコントローラが自動的に調整されており、航行型海中ロボット及び非航行型海中ロボットに対して、Imaginary Training が有効であることを示した。

PW45のコントローラは、約10回の航行により十分な調整が行なえているのに対し、Twin-Burgerの方位角制御のためのコントローラの調整には約500回の調整を要した。これは、初期コントローラの精度に起因している。ネットワークの構造や1回の学習データ数、運動特性が異なるために、単純に両者を比較することは難しい。しかしながら、予め評価関数に基づき現代制御理論を用いて調整を行ったコントローラの挙動を初期のコントローラに学習させることにより、調整時間の短縮を行なえると思われる。また、Imaginary Trainingは、搭載したプロセッサの処理能力に依存するので、今後より高速なプロセッサをロボットに搭載することにより高速化が行える。

R-one Robotの制御シミュレーションから分かるように、定常状態においてコントローラは非零の操作信号を出力している。実験データを教示データとして学習した場合、運動モデルが非対称な動特性を表現可能であるため、運動モデル内に外乱の影響を含むことになる。従って、シミュレーションの結果は、Identification Networkを運動モデルとして導入し、コントローラを調整することにより、非対称な制御対象の動特性や海中ロボットの運動に比べて十分に長周期な外乱に対して、対処し得ることを示している。

また、逆の観点から考えると、外乱に応じた力をコントローラが出力することから、外乱の大きさを推定することが可能である。つまり、運動モデルを常時更新し、得られた運動モデルの制御シミュレーションをすることにより、外乱に相当する力の大きさを算出することが可能となる。

ニューラルネットワークを用いたコントローラでは、入出力関数にシグモイド形状の関数を用いているため、出力層から得られる $[0, 1]$ の範囲をある一定の領域に変換して制御信号を出力する。そのため、制御信号のリミットが予め存在し、アクチュエータに余力が存在する場合や、新たに付加する場合への対応が困難で

ある。本論文のコントローラ調整法においても、適応制御やロバスト制御において成されているように、外乱に相当する力の成分と目標値への制御出力の成分を分離することが可能である。従って、本章で提案した運動制御システム ITNN に外乱の推定機構を導入することにより、より柔軟な制御システムへ発展が期待できる。次章では、オンラインでの運動モデルの更新、コントローラの調整、外乱の評価を行い、提案する運動制御システム ITNN の柔軟性について検討する。






Fig. 5-1(a) Direct adaptation approach by Yuh.

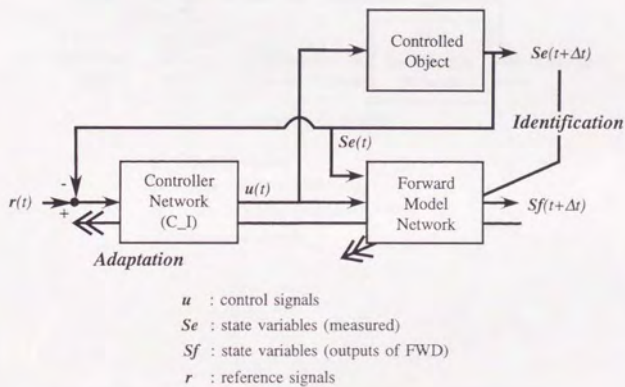


Fig. 5-1(b) Indirect adaptation approach by Fujii.

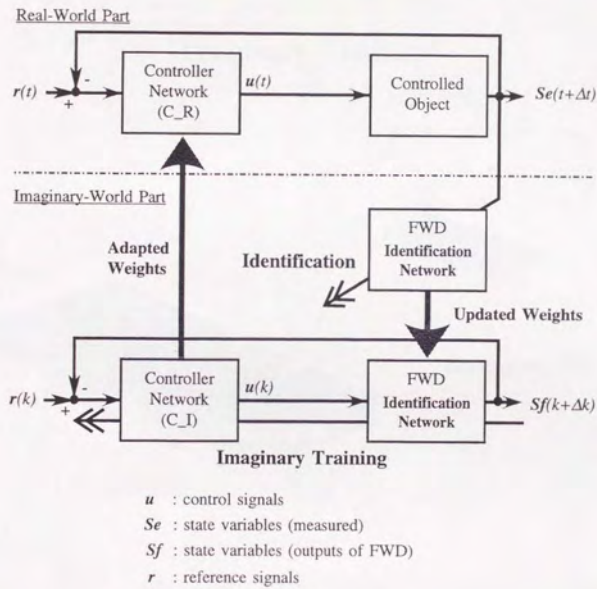


Fig. 5-2 Block diagram of proposed control system ITNN  
 (Imaginary Training system with Neural Network).






Fig. 5-3 Concept of Imaginary Training.




Fig. 5-4 Overall structure to simulate longitudinal motion of PW45.






Fig. 5-5 Experimental results controlled by initialized controller and outputs of dynamical model.




Fig. 5-6 Adaptation carried out in the Imaginary-World Part.






Fig. 5-7 Transition of evaluated value.




Fig. 5-8 Experimental results controlled by adjusted controller.




Fig. 5-9 Structure of Imaginary-World Part to deal with heading motion of Twin-Burger.






Fig. 5-10 Mapping function to initialize controller.




Fig. 5-11 Experimental results controlled by the initialized controller and the controller with the simple rule.




Fig. 5-12 Comparison of emulated motion controlled by the adjusted controller and the initialized one.




Fig. 5-13 Transition of evaluated value.






Fig. 5-14 Experimental results controlled by the adjusted controller (disturbance).




Fig. 5-15 Experimental results controlled by the adjusted controller (initial offset).




Fig. 5-16 Network structure to express the heading motion of R-one robot.

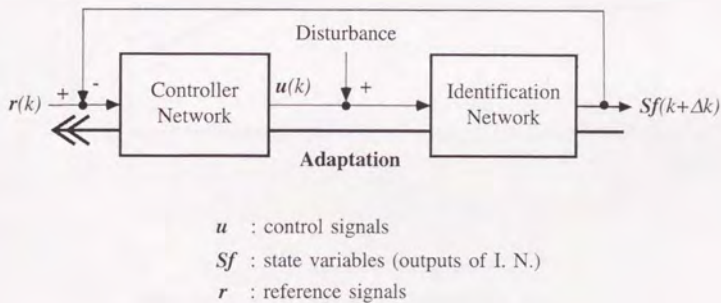


Fig. 5-17 Block diagram to simulate heading motion of R-one robot.




Fig. 5-18 Heading control simulation  
when thrust signal equal to 150 without disturbance.






Fig. 5-19 Heading control simulation  
when thrust signal equal to 150 with constant disturbance.




Fig. 5-20 Heading control simulation  
when thrust signal equal to 150 with sinusoidal disturbance.

Table 5-1 Evaluated value of control performance under various condisions.

Thrust Signal [rpm]	Disturbance [deg, Hz]	Control Error [ $\times 10^{-3}$ ]
120	-	4.42
120	(5.0, 0.0)	4.27
120	(5.0, 0.1)	4.42
150	-	4.47
150	(5.0, 0.0)	4.26
150	(5.0, 0.1)	4.47
180	-	4.36
180	(5.0, 0.0)	4.23
180	(5.0, 0.1)	4.42



## 第6章

# オンライン並列処理による 外乱への適応

## 6. 1 はじめに

運動制御システムを評価するには、未知の情報に対する適応性の検討を行なう必要がある。第5章において、提案したコントローラ調整手法「Imaginary Training」により、評価関数に基づいたコントローラが高速生成されることを確認した。本章では、外乱に起因して制御対象の動特性が変化する状況において、本論文において提案する ITNN の適応性を検討する。

ITNN は、並列処理能力を有するコンピュータシステムにおいて十分に能力を発揮する設計であり、ITNN の並列処理構造の実現も容易である。そこで、制御対象として、並列処理機能を有し演算能力の高いコンピュータシステムを搭載している Twin-Burger を用いる。シミュレーション及び実験において、Twin-Burger に対して外乱を加え、運動モデルの修正及びコントローラの調整をオンラインで行なうことを考える。実験では、問題設定の簡略化のため、まず Twin-Burger の Yaw 運動のみを取り扱う。外乱は自身に搭載されている左右のスラストを用いて生成し、方位角に関する角度、角速度及び角加速度と、操作量である Yaw モーメントを取り扱い、オンラインでの外乱への適応を検討する。次に、外乱として潮流を考え、ポジショニングシステムを用いた絶対座標系での経路追従を試みる。

## 6. 2 オンライン並列処理

Twin-Burger は、複数の Transputer から構成されるマルチプロセッサシステムを搭載している。第2章において述べたように、有限のシリアルリンクしか持たないマルチプロセッサシステムの取り扱いを容易にし、各プロセスの開発が独立して行えることを考え、各プロセッサの2本のシリアルリンクをパイプライン状に接続し、循環路を持つシステム構造としている。循環路を用いて、Twin-Burger のオペレーションに必要な基本的な状態量や変数を 10 Hz で通信している。

ITNN の適応能力を最大限に発揮するために、実機の制御プロセス、コントローラ調整プロセス及び運動モデル更新プロセスを各々別のプロセッサに配置することを考え、Fig. 6-1 に示すようなネットワーク構造及びプロセス配置を有するマルチプロセッサシステムとした。ITNN における各プロセスは、図中央部の四角で囲まれた3個のトランスピュータに配置し、残りの2本のシリアルリンクを用いて結合荷重の受け渡しを行なう。

Imaginary-World Part に属するプロセスは、Controller Adaptation 及び Forward Modelling と記された2つのプロセスであり、Motion Control プロセスは Real-World Part に属する。Fig. 6-2 の各プロセスの関係及び通信する変数を示す。スラスト等のアクチュエータへの指示及びデータの採取以外の通信は、基本的に非同期で行われるため、プロセッサの処理における待ち時間を減少させることが可能となる。

以下に、各プロセスとその機能について述べる。

### 1) Motion Control Process

Motion Control プロセスでは、Control Adaptation Process から得られた最新の結合荷重を用いて実機の制御を行なう。コントローラC\_Rの結合荷重の更新頻度はプロセッサの処理能力に依存し、コントローラC\_Iの結合荷重を受信した後、非同期に更新する。コントロールレートは10 Hzである。

### 2) Controller Adaptation Process

実時間での処理とは関係なく、最新の運動モデルを用いてコントローラC\_Iの調整を行なう。運動モデルの更新は、Forward Modelling Process からの通信に基づき非同期に行う。コントローラC\_Iの結合荷重は、ある一定回数の調整後 Motion Control Process に送信される。

### 3) Forward Modelling Process

外乱や制御対象の動特性の変化に適応するため、ある一定の期間の状態量を教示データとして学習し、運動モデルの更新を行う。一定回数の学習後、運動モデルの結合荷重をController Adaptation Process に対して非同期で送信する。その後、教示データを更新し、新しいデータを用いて運動モデルの追加学習を行う。運動モデルの更新頻度は、コントローラの調整と同様、プロセッサの処理能力に依存する。

これらのプロセスから構成される ITNN の各処理を時系列で表現すると Fig. 6-3 に示されるようになる。センサからのサンプリングは10 Hz で行われている。Forward Modelling Process において、ある一定回数学習した後、運動モデルの結合荷重が Controller Adaptation Process に送信される。Controller Adaptation Process では、送信された結合荷重を用いて運動モデルの更新を行い、その運動モデルを用いてコントローラC\_Iの調整を行う。ある一定回数のコントローラ調整後、調整後の結合荷重を Motion Control Process に送信する。Motion Control Process では、コントローラC\_Rの結合荷重をC\_Iの結合荷重に変更し、アクチュエータに対して操作信号を10 Hz で送信する。ここで述べた一連のプロセスをTwin-Burgerのマルチプロセッサシステムにおいて実現し、ITNNの外乱に対する適応能力の検討を行う。



## 6.3 外乱への適応

## 6.3.1 長周期の外乱への適応

長周期の外乱への適応性を検討するため、Twin-Burgerに対し、外乱として2.0 [Nm]の外力を加え、方位角制御を行なう。Twin-Burgerのミッションは、外乱が存在する環境において、振幅 0.5 [rad]、周期 20 秒の矩形波状に変化する目標方位角  $\psi_r$  の追従とする。また、外乱は左右のスラストを用いて生成するものとする。運動モデル及びコントローラの評価式として (6.1) 式、(6.2) 式を用いる。ここで、 $\psi_e$  は実験データ、 $\psi_r$  は制御目標値である。

$$Ef = 1/2 \sum_k \{(\psi(k) - \psi_e(k))^2 + (\Delta\psi(k) - \Delta\psi_e(k))^2\} \quad (6.1)$$

$$Ec = 1/2 \sum_k \{(\psi(k) - \psi_r(k))^2 + (\Delta\psi(k) - \Delta\psi_r(k))^2\} \quad (6.2)$$

まず、ITNN のシステム全体の有効性を確認するため、ITNN を Twin-Burger のシステムに搭載し、第5章において得られた運動方程式を用いてシミュレーションを行なった。そのシミュレーションにおける制御結果を Fig. 6-4 に示す。上から操作量、方位角速度、方位角、運動モデルの更新回数及びその評価値を表している。目標方位角に対して良好に追従している。方位角が 0.5 [rad] 或いは -0.5 [rad] に安定している期間において約 -2.0 [Nm] を出力しており、これは外乱の大きさとは一致する。運動モデルの評価値の推移から、追加学習により運動モデル内に外乱を含むように学習していることが分かる。

このときの、運動モデルの出力結果を Figs. 6-5, 6-6 に示す。Fig. 6-5 は運動モデルの学習を行なわない場合の出力であり、後半部において大きな誤差が存在する。一方、Fig. 6-6 は学習を常時行なった場合の出力であり、外乱の影響を運動特性の変化として学習している。Imaginary Training における制御シミュレーションの結果を Fig. 6-7 に示す。目標方位角である 0.5 [rad] に制御されている約 8 秒付近において、コントローラ  $C_I$  が -2.0 [Nm] を出力しており、外乱に適応していることが分かる。このシミュレーション結果から、長周期の外乱に対して ITNN の適応機能が動作することを確認した。

これらのシミュレーションから、提案したシステムが機能することが判明したので、水槽において同様の実験を行った。実験結果を Fig. 6-8 に示す。オーバーシュートが存在するもの、シミュレーションと同様、良好に制御されている。運動モデルの誤差値は、実験開始直後において大きいものの、実験が進むに連れて収束している。このときの運動モデルの出力と実験値の比較を Figs. 6-9, 6-10 に示す。Fig. 6-9 は運動モデルを調整していないため、シミュレーションと同様に、後半部に誤差が積分され大きくなっている。一方、常時学習を行った場合、一定外乱を動特性の変化として学習できることが Fig. 6-10 から判断できる。Imaginary Training におけるコントローラ調整の様子を Fig. 6-11 に示す。約 8 秒においてコ

ントローラC-Iの出力は約-1.5 [Nm]であり、外乱とはほぼ同じ大きさのモーメントを出力している。この図からも運動モデルが外乱の影響を動特性の変化として学習していることが分かる。

以上のシミュレーション及び水槽実験の結果から、ITNNは一定の外乱に対して有効的に機能しており、コントローラ調整時間に比べて十分に長い周期の外乱に対して十分に適応できると思われる。

### 6. 3. 2 周期的な外乱への適応

ここでは、外乱として振幅2.0 [Nm]、周期5秒の正弦波状のモーメントを加え、その場合のシステムの応答を検討する。Twin-Burgerの目標軌道は、前節同様、幅0.5 [rad]、周期20秒の矩形波状に変化する目標方位角 $\psi_r$ の追従とする。

第5章の運動方程式を用い、Twin-Burgerのコンピュータシステムにおいてシミュレーションを行った結果をFig. 6-12に示す。操作量入力の図に周期外乱を併せて表示している。シミュレーションでは、コントローラが外乱の逆位相の制御信号を出力しており、方位角及び方位角速度に周期外力の影響が現れていない。それに伴い、制御結果も良好である。運動モデル及びコントローラ調整の評価値は、一定の外乱を与えた場合に比べて安定している。運動モデルの出力とシミュレーション結果の比較をFigs. 6-13, 6-14に示す。常時学習を行った運動モデルの方が良好な出力をしているものの、周期外力を制御対象の運動特性の変化として扱っていない。Fig. 6-15にImaginary Trainingの過程における制御シミュレーションの結果を示す。定常状態にある約8秒、20秒付近では、約-0.5 [Nm]を出力している。運動モデルの特性として周期外乱の影響は含まれておらず、一定外乱として学習していることが分かる。

水槽において実験した結果をFig. 6-16に示す。良好に目標値を追従しているが、シミュレーションにおける制御結果と違い、コントローラは周期的な制御信号を出力していない。これは、スラストの不感帯による影響があるため、外乱の生成信号に対して追従できていないためと思われる。

Figures 6-17, 6-18に運動モデルの出力と実験結果の比較を示す。Fig. 6-17は学習を行なわなかった場合の結果であり、Fig. 6-18はサンプリングデータを教示データとして常時学習した場合の結果である。常時学習することにより、運動モデルが実機の運動をより正確に表現できることが分かる。実験結果には多少の周期外力の影響がみられるものの、運動モデルは雑音として捉えている。Imaginary Trainingによるコントローラ調整の結果をFig. 6-19に示す。図からも良好なコントローラが得られていることが分かる。定常状態において、約1.0 [Nm]を出力しており、正弦波状の周期外乱が負のモーメントとして捉えられている。

以上のシミュレーション及び実験結果からITNNが、設計通り有効的に機能していることが分かる。定常的な外乱に対しては、動特性の変化として運動モデル



内部に取り込み、周期的な外力に対してはコントローラが逆位相の出力をすることにより、システム全体として外乱に対して柔軟な機能を有している。

## 6. 4 潮流に対する適応

海中ロボットの運動を考えた場合、深度及び方位角に関しては絶対的な物理量が得られるため、外乱の影響を動特性の変化として取り扱うことが可能である。一方、潮流等の外乱を想定した場合、絶対的な変化量は、周囲の支援設備との交信、或いは、海底面近傍を航行しドップラーソナーを用いた対地速度の計測等からしか得られない。そのため、外乱の判定として、相対的な物理量と絶対的な物理量の比較が必要となり、外乱への適応は高レベルの知的判断が必要となる。

ここまで、ITNNをYaw運動に適用し、その有効性を検討してきた。本章では、ITNNをSurge、Sway、Heave、Yawの4つの運動に対して適用し、潮流に代表される外乱の推定及び適応法を考察する。

### 6. 4. 1 SSBLを用いた外乱の推定

海中におけるポジショニングシステムには、LBL (Long Base Line)、SBL (Short Base Line)、SSBL (Super Short Base Line) 等の手法が存在し、それぞれ一長一短がある。LBLは、親機と子機の距離から三角測量により位置の特定を行なうシステムであり、高い精度で位置特定ができる。その反面、予め子機を設置し、位置関係のキャリブレーションをする必要があり、システム全体として大がかりなものとなる。SBL及びSSBLによる位置特定システムは、子機をロボットに取り付け、母船上の親機において、子機からの信号の位相差に基づいて位置を特定するシステムである。小さなシステムににより構築でき、取り扱いも簡便であるが、精度に問題がある。

Twin-BurgerはSSBLによるポジショニングシステムを搭載しており、親機からのピンガーに対して子機が応答し、その時間差と位相差及び子機が有する深度計のデータから位置情報を算出する。Twin-Burgerに搭載されている流速計を用いDead reckoningによる位置情報と、SSBLにより得られる位置情報を比較することにより、潮流などの外乱を判定することが可能である。

本論文において構築した位置特定システムをFig. 6-20に示す。SSBLの親機と支援設備であるホストコンピュータはRS232Cにより接続され、ホストコンピュータからの信号に基づいてピンガーを出力する。ここでは毎秒一回位置の特定を行う。得られた位置情報は、ホストコンピュータのPIOボードを介して超音波通信システム (Ultrasonic Command Link) に送られ、超音波によりTwin-Burgerと通信し位置情報を伝える。ここで用いている超音波通信システムは、毎秒約8bitsの通信しか行えないため、8bit通信を3回行い位置情報を送信している。また、SSBLと通信システムが使用する周波数帯が近いため、SSBLと通信システムは0.5秒間隔で交互に超音波通信を行っている。



潮流を扱うには大規模な実験設備が必要となるため、三井造船昭島研究所の潮流水槽にて実験を行なった。実験に先立ち、SSBLのキャリブレーションを行なった。その結果をFig. 6-21に示す。得られたデータには、雑音の影響がかなり存在するため、カルマンフィルタ[106]を用いたフィルタ処理を行なっている。Fig. 6-21から親機の軸が時計周りに30度回転していることが判明した。

補正を行い、外乱の判定が可能であるか検討するため、子機をTwin-Burgerに搭載し、潮流がない状態で定点保持実験を行なった。SSBLにより得られた位置情報とDead-reckoningの結果の比較をFig. 6-22に示す。外乱が存在しないにも関わらず、かなりの違いがみられる。得られた情報から最小2乗法を用いて1次式で近似し、オンラインで外乱を判定した結果がFig. 6-23である。上の2つの図が絶対座標系における位置座標を表し、3つめの図が絶対座標系における外乱の推定値、4つめの図が機体座標系に変換した外乱の推定値である。外乱を加えていないにも関わらず、Twin-Burgerの運動能力に比べて大きな外乱が推定されている。本論文では、潮流として最大8 cm/secを想定したが、SSBLに起因する外乱がその想定を超えるため、ここではSSBLによる外乱判定を断念し、予めTwin-Burgerに潮流の大きさと方向を与え、潮流が判定できたとして実験を行った。以下では、潮流は方位角0 [rad]の方向から大きさ8 [cm/sec]の2次元流として実験を行なった。

#### 6. 4. 2 外乱への適応法

前節において示したように、一定な外乱の影響は運動モデル内に取り込むことが可能であり、非対称な動特性として外乱を扱うことができる。Imaginary Trainingにより運動モデルを定常状態になるよう制御した場合、運動モデルの非対称な動特性に起因して、コントローラの出力に定常偏差が現れる。この定常偏差は、運動モデルが学習した一様外乱に相当する力であると考えられる。以上の考えに基づき、Fig. 6-24に示すように外乱推定機構を付加し、外乱に相当する力をフィードバックコントローラの出力値に加算することを考える。

ニューラルネットワークを用いたコントローラでは、応答関数としてシグモイド形状の関数を用いているため、予め決定したある一定の範囲に存在する値を出力する。そのため、外乱の大きさがコントローラの出力より大きい場合、外乱に対処することが困難である。本論文では、目標軌道追従のための制御力と外乱に対する制御力を分離することにより、スラストの追加や外乱の影響に対して柔軟に対応することを考える。

ここでは、Surge、Sway、Heave、Yawに関する運動を取り扱うので、第5章に述べた手法に基づいて、各々独立に初期コントローラを作成した。コントローラの構造は、Yaw運動のコントローラと同じく、2 (リカレント+5) -5-1のニューロン数とした。得られた結果をFigs. 6-25~27に示す。各運動について良好な初期コントローラが得られていることが分かる。

## 6. 4. 3 潮流存在下での経路追従実験

Twin-Burgerのミッションとして、3 m x 3 m の正方形パスのトラッキングを考える。これは、潮流水槽の大きさと安全性の確保を考慮して決定した。このミッションにおけるプロセッサ及びプロセスの配置をFig. 6-28に示す。各運動モードのコントロールシステムを4つのTransputerに独立に配置し、経路の決定や超音波による通信、外乱の判定等の処理も別のプロセッサにおいて処理している。Fig. 6-29 に示すように、1つのTransputer内に各運動モードに対応したMotion Control Process、Controller Adaptation Process、Forward Modelling Processが配置されており、各々独立して演算が行われている。

Forward Modelling Processでは、最新の20秒間のデータを教示データとし、20回の運動モデル調整毎にController Adaptation Processに対して結合荷重を送信する。ここで、運動モデルの教示データを考慮しなければならない。良好な制御が行なわれた場合、教示データである実験データは安定した値となる。そのため、学習領域が小さくなり、運動モデルが正しく調整されない可能性がある。適応制御の分野で行われているように、(6.3)式で示される不感帯を導入する[107,108]。

$$\Delta w_f = \begin{cases} 0 & \text{if } |Ef| < \gamma \\ \Delta w_f & \text{if } |Ef| \geq \gamma \end{cases} \quad (6.3)$$

ここで、 $\Delta w_f$ は運動モデルの結合荷重修正量、 $Ef$ は運動モデルの評価値であり、 $\gamma=0.001$ とした。Controller Adaptation Processでは、1回のコントローラ調整毎にMotion Control Processに対して最新のコントローラの結合荷重を送信する。更に、運動モデルが更新される毎に運動特性の変化として取り込まれた外乱の大きさを推定する。Motion Control Processは、最新の結合荷重を用いて10 Hzで運動の制御を行なう。

潮流は方位角0 [rad]の方向、つまり、水槽の上流に相当する方向から約0.08 m/secの速度で存在する。ミッションを具体的に述べると

- 1) 流れに逆らい、絶対座標系で4 m前進する。つまり、潮流により流された距離に加えて更に4 mの距離を進む。(A地点→B地点)
- 2) 時計周りに回頭し、流れを横切り絶対座標系で3 m前進する。(B→C)
- 3) 時計周りに回頭し、流れに沿って絶対座標系で3 m前進する。(C→D)
- 4) 時計周りに回頭し、流れを横切り絶対座標系で3 m前進する。(D→E)
- 5) 時計周りに回頭し、定点を保持する。(E)

のようになる。実験における各運動モードの制御結果をFigs. 6-30~33に示す。順にSurge、Sway、Heave、Yawに関して得られたデータであり、上から速度、位置、操作量を表している。以下に、各運動モードの制御結果について述べる。



## (Surge 運動)

Figure 6-30 の上の2つの図において、太線が実験データ、細線が目標軌道、点線が外乱を示している。下図では、点線がフィードバックコントローラの出力、太線が外乱に対応した出力、細線が両者を加えた最終的な出力を表している。

最初の約30秒間で流れに逆らい、目標前進距離約7.5[m]に対して約6[m]前進している(A→B)。初期のコントローラは、外乱推定機構を導入していないシステム構成において調整されたため、外乱の取り扱いが良好に行えず、目標軌道に追従できていない。また、潮流に相当する力は約0.5[N]と推定しており、潮流に対して逆方向の力を生成している。

Figure 6-34 から分かるように、オンラインでの運動モデルの更新及び、それに基づくコントローラ調整に約60秒間要している。そのため、流れを横切る方向に運動した約50秒から80秒の間(B→C)においても、目標軌道に対して偏差が存在する。これは、外乱推定機能において約-1.5[N]を出力していること、フィードバックコントローラの出力範囲が[-10,10][N]であることにも起因する。約80秒後以降では(C→D、D→E)、外乱の推定機構も良好機能しており、目標軌道に対して良好に追従できている。

Figures 6-35, 36はImaginary-World Partにおける運動モデルの出力とコントローラ調整の様子を表している。運動モデルが制御対象の運動を良く表現できていること、コントローラが外乱の推定機構を含めて目標軌道を追従するように調整されていることが分かる。調整には(6.4)式及び(6.5)式を用いた。ここで、 $u$ は運動モデルから得られた前進速度、 $u_e$ は制御対象において観測された前進速度、 $u_r$ は目標前進速度とする。

$$Ef = 1/2 \sum_k \{ (u(k) - u_e(k))^2 + (\Delta u(k) - \Delta u_e(k))^2 \} \quad (6.4)$$

$$Ec = 1/2 \sum_k \{ (u(k) - u_r(k))^2 + (\Delta u(k) - \Delta u_r(k))^2 + 2.0(\Delta^2 u(k) - \Delta^2 u_r(k))^2 \} \quad (6.5)$$

Twin-Burgerに搭載されている流速計は、-3.0[cm/sec]から3.0[cm/sec]に不感帯が存在するため、得られたデータには全体的に振動が見られるものの、実験の進行に伴って、最終的に目標軌道の追従が行なえている。これらの結果から、ITNNにおける学習の効果が確認できる。

## (Sway 運動)

Figure 6-31 に示される sway 運動において、実験開始直後、ミッションの開始とデータ初期化のタイミングの問題により、目標軌道にオフセットが残っている。そのため、最初の約30秒間(A→B)は目標の追従ができていない。約40秒の地点において、約-14[N]を出力しているものの、流速計は正の値を出力している。これは、Yaw運動の影響であり、運動モデルの構造にモード間の干渉が含まれて



いないためである。これは、Fig. 6-37に示される運動モデル及びコントローラの評価値の推移にも現れており、Yaw運動に伴って評価値の振動が発生している。

約50秒から80秒の間は(B→C)、制御対象が流れを横切っているため横流れが存在し、負の方向つまり流れの上流に向かって目標軌道が設定されており、制御対象の運動も良好に行われている。約140秒から180秒においても(C→D)、流れを横切るため潮流の影響が大きくなる。それに伴う外乱を10[N]と推定しており、良好な結果が得られている。また、約40秒と180秒の回頭時における運動を比較すると、コントローラが良好に調整されていることが分かる。

Figure 6-38に運動モデルの出力と実験データの比較した結果を示す。運動モデルの教示データには、流速計の不感帯の影響が現れているものの、良好にsway運動の表現が行なわれている。コントローラ調整の様子をFig. 6-39に示す。制御シミュレーションの結果からコントローラの調整が良好に行われていることが分かる。調整において用いた評価式を(6.6)式及び(6.7)式に示す。ここで、 $v$ は運動モデルから得られた横方向の速度、 $v_e$ は制御対象において観測された横方向の速度、 $v_r$ は横方向の目標速度とする。

$$Ef = 1/2 \sum_k \{ (v(k) - v_e(k))^2 + (\Delta v(k) - \Delta v_e(k))^2 \} \quad (6.6)$$

$$Ec = 1/2 \sum_k \{ (v(k) - v_r(k))^2 + (\Delta v(k) - \Delta v_r(k))^2 + 2.0(\Delta^2 v(k) - \Delta^2 v_r(k))^2 \} \quad (6.7)$$

#### (Heave 運動)

Heave運動の目標値は、常に0[m](深度2.5[m])であり、全体的に良好に制御されている。Heaveの運動モデルは、Heave運動の制御目標が一定であるため、同じような教示データにより調整されることになり、過学習という問題が生じる。適応制御の分野では、不感帯の設定や $\sigma$ -修正法を用いて推定機構の発散を防止する等の工夫がなされており、ニューラルネットワークによる適応適則にも導入する必要があると思われる。本論文では、先に述べたように不感帯を設定しているため、Fig. 6-40に示される運動モデルの評価値は安定している。それに伴い、コントローラの調整も良好に行えている。

Figure 6-41は運動モデルの出力と実験データの比較を表している。実験データには、Heaveの運動に比べて短い周期の振動が含まれているが、運動モデルは実験データの平均値に近い値を出力しており、定性的な傾向を表現できている。Fig. 6-42に示される制御シミュレーションにおいても良い制御結果が得られている。調整において用いた評価式を(6.8)式及び(6.9)式に示す。ここで、 $w$ は運動モデルから得られた深度変化速度、 $w_e$ は制御対象において観測された深度変化速度、 $w_r$ は横方向の目標速度とする。

$$Ef = 1/2 \sum_k \{ (w(k) - w_e(k))^2 + (\Delta w(k) - \Delta w_e(k))^2 \} \quad (6.8)$$

$$Ec = 1/2 \sum_k \{ (w(k) - w_r(k))^2 + (\Delta w(k) - \Delta w_r(k))^2 + 2.0(\Delta^2 w(k) - \Delta^2 w_r(k))^2 \} \quad (6.9)$$

## (Yaw 運動)

Figure 6-33に示されるように、Yaw運動に関しても、全般に渡って良好に制御されている。実験開始からの約180秒は、コントローラ調整が進むに連れて、操作量に存在する振動の振幅も減少している。それに伴い、方位角速度に存在する振動が減少している。後半において操作量信号の振幅が大きくなっている。これは、局所的な磁場のため得られる方位角と実際の方位角に誤差が存在し、あたかも方位角により運動特性の変化が生じるように捉えられるためである。

コントローラ及び運動モデルの評価値の推移をFig. 6-43に示す。実験開始直後運動モデルの誤差が大きいため、コントローラの評価値も大きくなっているものの、全体として安定に調整されている。Fig. 6-44に運動モデルの出力と教示データの比較を示す。良好な結果を示しているが、教示データが単調であり、全体的な学習が行えていない。不感帯を設定しない場合、運動モデルの評価値に振動が生じる場合があることを確認している。Fig. 6-45はImaginary Trainingにおける制御シミュレーションの結果である。外乱として推定された力は約0.2[Nm]であり、0.08 [m/sec]の流れによる運動特性への影響は小さいと思われる。調整において用いた評価式を(6.10)式及び(6.11)式に示す。ここで、 $\psi$ は運動モデルから得られた方位角、 $\psi_e$ は制御対象において観測された方位角、 $\psi_r$ は横方向の目標方位角とする。

$$Ef = 1/2 \sum_k \{ (\psi(k) - \psi_e(k))^2 + (\Delta \psi(k) - \Delta \psi_e(k))^2 \} \quad (6.10)$$

$$Ec = 1/2 \sum_k \{ (\psi(k) - \psi_r(k))^2 + (\Delta \psi(k) - \Delta \psi_r(k))^2 + 2.0(\Delta^2 \psi(k) - \Delta^2 \psi_r(k))^2 \} \quad (6.11)$$

全体の運動軌跡をFig. 6-46に示す。Dead-reckonngによる軌跡と、潮流の影響を考慮した絶対座標系における軌跡を表している。X軸方向に誤差が存在するものの、外乱として潮流が存在する環境において、ITNNにより良好な制御結果が得られる。



## 6.5 考察

本章では、運動制御システムの良し悪しは未知な動作環境での適応性により判断できるという判断のもとに、外乱に起因する制御対象の動特性の変化を取り扱い、提案する運動制御システム ITNN の適応能力の検討を行った。

ITNN は並列処理能力を有するコンピュータシステムにおいて、十分に能力を発揮できるシステムである。そこで、Transputer で構成されるマルチプロセッサシステムに搭載し、シミュレーションと水槽実験において、運動モデルの更新及びコントローラ調整を行なった。方位角制御問題の結果から、長周期の外乱の影響は、運動特性の変化として運動モデル内に取り込まれること及び、周期的な外乱に対しては、コントローラが逆位相の出力をすることを確認した。この結果は、ニューラルネットワークを用いた適応制御が有効であることを示している。今後、様々な周波数の外力に対する応答や外乱の強さの影響を検討し、定量的に評価を行なう必要がある。

潮流等の外乱に対処するため、ITNN に外乱の推定機構を付加し、水槽実験において動作を確認した。通常的手法では、外乱の大きさの評価を定常状態における操作量から算出する。その場合、雑音の大きさや周波数分布に大きく影響されるが、本論文的手法では、運動モデルの出力から算出するため取り扱いが容易である。更に、外乱の推定機構を付加した ITNN では、通常の制御力と外乱に相当する力を分離することができる。ニューラルネットワークを用いたコントローラでは、初期の設計において制御信号の取り得る範囲を決定するため、アクチュエータの付加や変更への対処が容易に行なえない。本論文的手法では、上記の問題に対処できるため、より柔軟なコントロールシステムへの発展が期待できる。

オンラインによる推定機構の問題点は、良好な制御が行われた場合、教示データの領域が小さくなり発散する可能性が存在することである。適応制御の分野では、不感帯法や調整則を1次遅れ形式に変形した  $\sigma$ -修正法等を用いて、適応制御システムをロバスト化する手法が考案されている。ニューラルネットワークの調整則にも、これらの手法の導入を検討する必要がある。本論文では、不感帯を設定することによりシステムの安定化を行ない、実験結果からも良好な調整が行えることを確認した。今後、適応制御において行なわれているロバスト化等の手法を参考にし、ニューラルネットワークを用いた制御システムに、如何に既存の技術を取り入れるかが重要な課題となる。





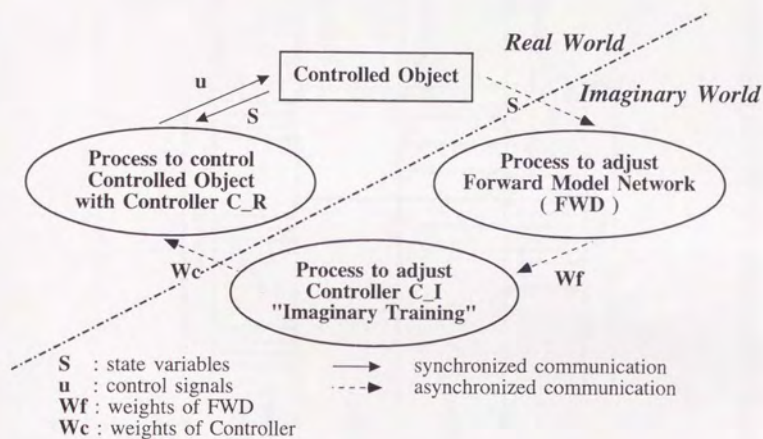


Fig. 6-2 Communication between processors.




Fig. 6-3 Timing of data processing and network updating in the on-line adaptation experiments.






Fig. 6-4 Heading control simulation using ITNN under constant disturbance.




Fig. 6-5 Output of Identification Network and equations of motion under constant disturbance. The Identification Network in this figure does not include the effect of disturbance and no additional learning is performed. So that the offset can be seen in this figure.




Fig. 6-6 Output of Identification Network and equations of motion under constant disturbance. The Identification Network in this figure includes the effect of disturbance by the additional learning.




Fig. 6-7 Performance of the controller C\_I in the simulation with equations of motion when the constant disturbance is given to the robot .






Fig. 6-8 Experiment results when the constant disturbance is given to the robot.




Fig. 6-9 Comparison of outputs of the FWD and experimental results when the constant moment is given to the robot and the FWD is not updated.




Fig. 6-10 Comparison of outputs of the FWD and experimental results when the constant moment is given to the robot and the FWD is updated.




Fig. 6-11 Performance of the controller C\_I in the experiment when the constant disturbance is given to the robot.






Fig. 6-12 Result of the control simulation  
when the sinusoidal moments are given to the robot.




Fig. 6-13 Output of Identification Network and equations of motion under sinusoidal disturbance. The Identification Network in this figure does not include the effect of disturbance and no additional learning is performed.




Fig. 6-14 Output of Identification Network and equations of motion under sinusoidal disturbance. The Identification Network in this figure includes the effect of disturbance by the additional learning.




Fig. 6-15 Performance of the controller C\_I in the simulation with equations of motion when the sinusoidal disturbance is given to the robot.






Fig. 6-16 Result of the control experiment when the sinusoidal moments are given to the robot.




Fig. 6-17 Output of Identification Network and experimental result under sinusoidal disturbance. The Identification Network in this figure does not include the effect of disturbance and no additional learning is performed.




Fig. 6-18 Output of Identification Network and experimental results under sinusoidal disturbance. The Identification Network in this figure includes the effect of disturbance by the additional learning.




Fig. 6-19 Performance of the controller C\_I in the experiment when the sinusoidal disturbance is given to the robot.



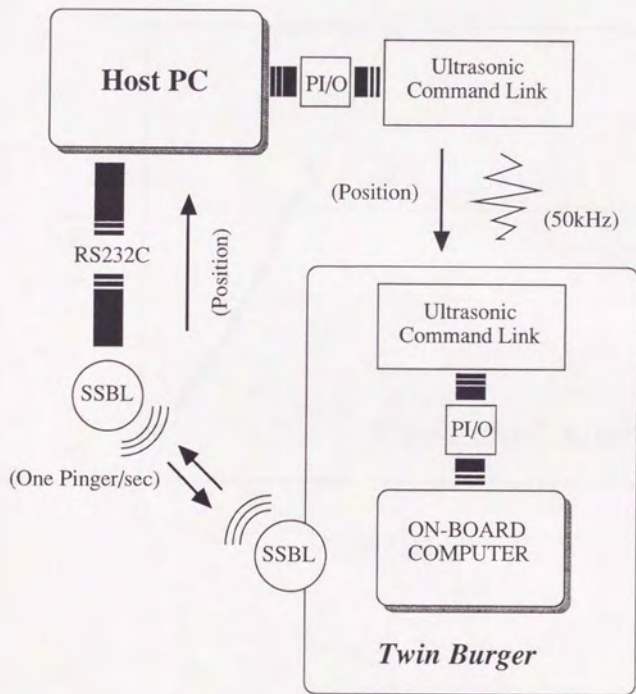


Fig. 6-20 SSBL positioning system for Twin-Burger.




Fig. 6-21 Calibration curve of SSBL positioning system.

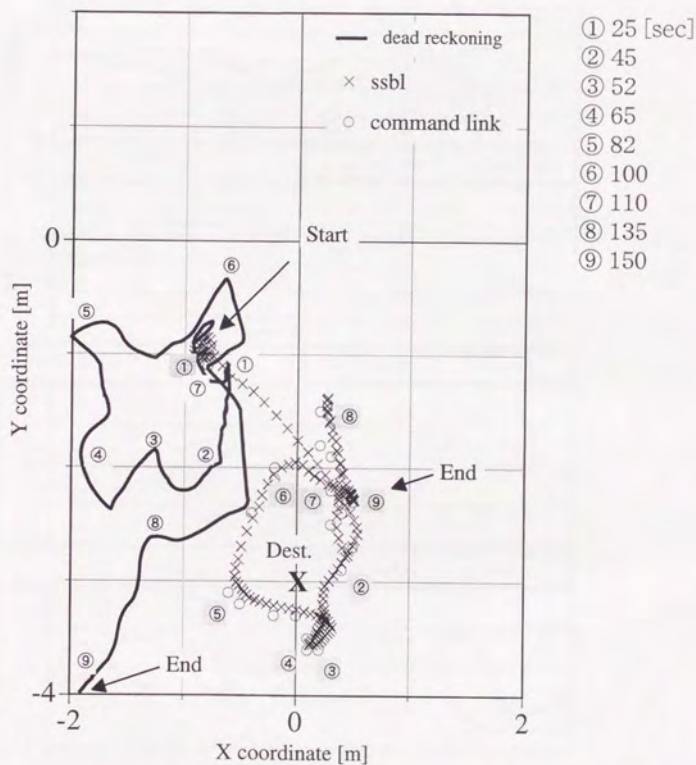


Fig. 6-22 Trajectory of the robot by dead-reckoning, SSBL data on host PC, and transmitted data by command link.






Fig. 6-23 Estimated disturbance calculated as the difference between position from dead-reckoning and from SSBL.






Fig. 6-25 Control results by initialized controller and target trajectory (surge).  
The Identification Network is used as the dynamical model.






Fig. 6-26 Control results by initialized controller and target trajectory (sway).  
The Identification Network is used as the dynamical model.




Fig. 6-27 Control results by initialized controller and target trajectory (heave).  
The Identification Network is used as the dynamical model.

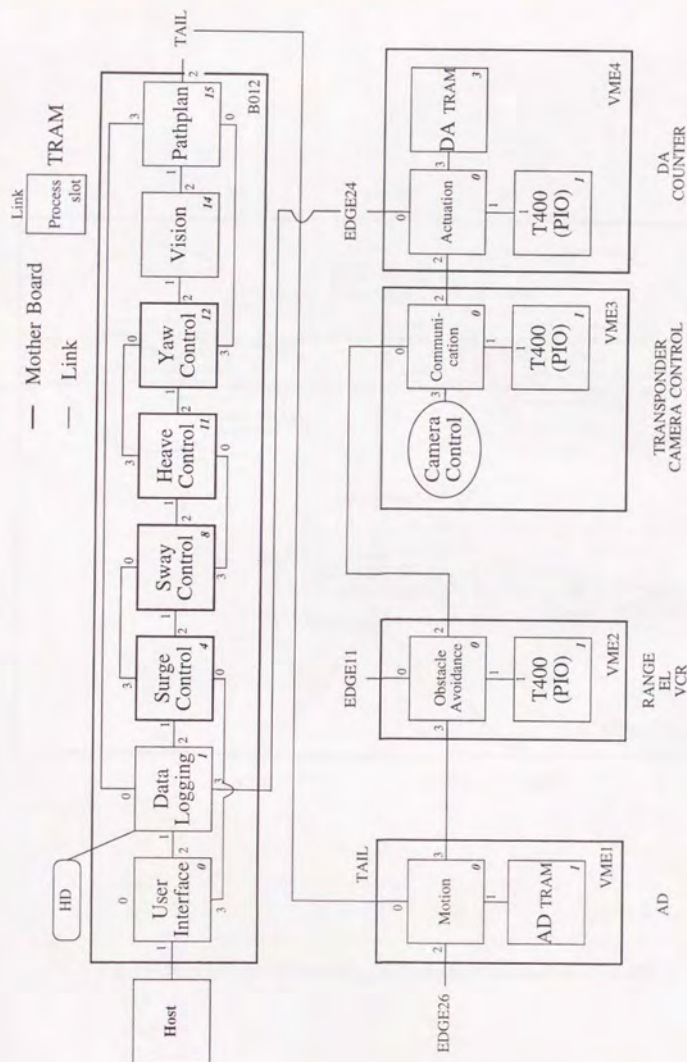


Fig. 6-28 Configuration of Transputer array & processes assigned.



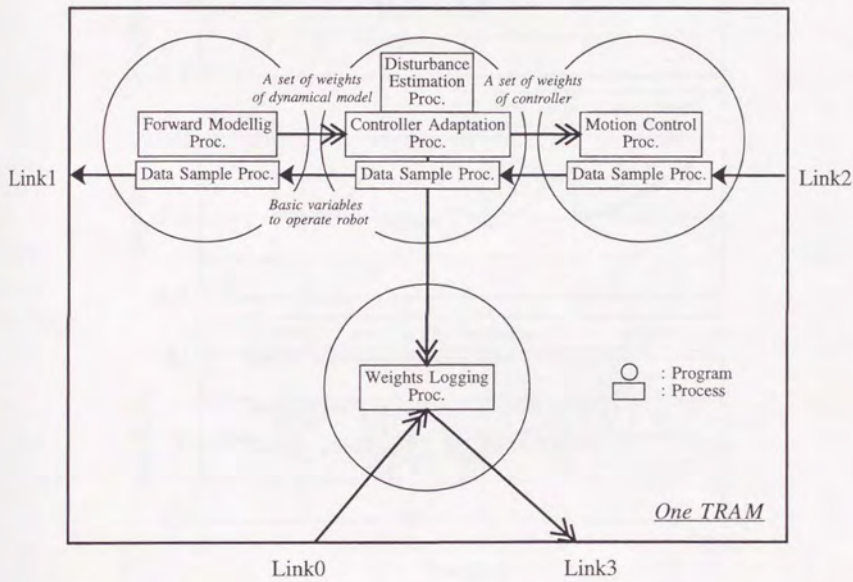


Fig. 6-29 Processes representing each motion located in a TRAM.




Fig. 6-30 Experimental results of surge motion. The current (0.08 [m/sec]) is given to the robot as the disturbance.




Fig. 6-31 Experimental results of sway motion. The current (0.08 [m/sec]) is given to the robot as the disturbance.






Fig. 6-32 Experimental results of heave motion. The current (0.08 [m/sec]) is given to the robot as the disturbance.




Fig. 6-33 Experimental results of heading motion. The current (0.08 [m/sec]) is given to the robot as the disturbance.




Fig. 6-34 Estimation error of dynamical model network and evaluated value of controller concerning to surge motion.






Fig. 6-35 Identification of surge motion. The input force consists of usual control force and force against the disturbance.




Fig. 6-36 Control results of surge motion in the imaginary-world part. Target trajectory is generated to deal with the disturbance (current). The Identification Network is used as the dynamical model.




Fig. 6-37 Estimation error of dynamical model network and evaluated value of controller concerning to sway motion.




Fig. 6-38 Identification of sway motion. The input force consists of usual control force and force against the disturbance.




Fig. 6-39 Control results of sway motion in the imaginary-world part. Target trajectory is generated to deal with the disturbance (current). The Identification Network is used as the dynamical model.






Fig. 6-40 Estimation error of dynamical model network and evaluated value of controller concerning to heave motion.




Fig. 6-41 Identification of heave motion. The input force consists of usual control force and force against the disturbance.




Fig. 6-42 Control results of heave motion in the imaginary-world part. Target trajectory is generated to deal with the disturbance (current). The Identification Network is used as the dynamical model.




Fig. 6-43 Estimation error of dynamical model network and evaluated value of controller concerning to yaw motion.






Fig. 6-44 Identification of heading motion. The input force consists of usual control force and force against the disturbance.




Fig. 6-45 Control results of heading motion in the imaginary-world part. Target trajectory is generated to deal with the disturbance (current). The Identification Network is used as the dynamical model.




Fig. 6-46 Trajectory of Twin-Burger.

## 第7章

### 考察



本論文では、ニューラルネットワークを用いた海中ロボットの運動の表現手法及び運動の制御手法について得られた成果について述べてきた。本章では、それらの成果を一望しながら、今後の展望について考える。

#### (海中ロボットの開発)

本研究の最終的な目的は、動作環境や運動特性の変化に対して柔軟に対処し、与えられた任務の遂行を自律的に行なう海中ロボットを開発することである。これまで、海中ロボットの自律的行動を実現するには実際に実環境において動作させることが重要であるという認識から、実際に海中ロボットの開発に携わり、実験を行ってきた。海中ロボットを開発する上で重要な要素として、開発目的を含めた設計思想と、搭載機器類のバランスが考えられる。MITのOdyssey IIやFAUのOcean Voyager II、Ocean ExplorerはLow-Cost AUVとして開発され、取り扱いの容易さや汎用性に重点をおいて設計されている。WHOIのABEは長期観測を目的として設計され、流体力学的な特性や消費エネルギー、信頼性などに工夫が見られる。東京大学生産技術研究所のTwin-Burgerは自律性を研究するためのテストベッドとして開発され、コンピュータシステムに特徴がある。今後、ロボットを開発する場合、ロボットの設計思想を明確に打ち出すことが重要であろう。

#### (運動の表現)

海中ロボットの自律的な行動を実現するにあたり、運動制御システムはその根幹となる技術である。運動制御システムにおいて、対象とするシステムの動特性の把握、システム同定が重要な意味を持つ。システム同定には、古典制御理論と関連して発展したインパルス応答、周波数応答、スペクトル密度等のノンパラメトリックモデルを用いる手法とARXモデルやFIRモデル等の有限個のパラメータにより特徴づけられる差分方程式(連続時間システムでは微分方程式)によるパラメトリックモデルを用いた手法がある。パラメトリックモデルは状態空間法に代表される現代制御理論の発展に伴って普及した手法である。実際のシステムをパラメトリックモデルにより表現する場合、モデルの次数や構造、推定法が問題となる。本論文において提案した運動モデル「Identification Network」は、状態方程式をニューラルネットワークにより表現しようとしたものであり、複数の結合荷重により構成されるパラメトリックモデルの1つとして見なすことができる。従って、ネットワークの構造や、ニューロン数の決定、学習法の選定など同様の問題が存在する。さらに、ニューラルネットワークを用いた場合、その挙動を理論的な見地から補償するするのは非常に困難であり、実機への実践によってのみその挙動の評価を行なわれる。しかしながら、入出力の応答関数として非線形な関数を用いていること、近年の計算機の能力の向上の恩恵が直接的に得られ

ること等の理由から、非線形性が強いシステムのモデルとして期待されている。本論文において海中ロボットを対象として構築した運動モデルは、その応答の評価結果から、運動モデルとして満足できるものであり、十分な精度を有することを示している。今後の課題として、

- ・ 学習係数及び回数などの決定法が確立されておらず、設計者のセンスによるところが多い。
- ・ 学習した領域以外での挙動が補償されていない。
- ・ どのクラスのシステムまで表現できるのか。

等が挙げられ、一層の理論的な展開が待ち望まれる。

#### (ニューラルネットワークの信頼性評価)

先にも述べたように、ニューラルネットワークの出力の評価は実践をもって行っている。そこで新たな信頼性を評価するネットワークを付加する手法を考案した。これは、学習した領域に対しては"1"、それ以外の領域においては"0"を出力するネットワークであり、学習時のパラメータを適切に調整すれば、教示データに対応した空間の分割が可能であることを示した。明確な境界を持つ空間分割法ではないので、より柔軟なシステムへの発展の可能性が考えられるが、ネットワークの構築が容易でない。興味深い題材ではあるが、実際に適用するに当たって、学習方法の確立や精度について議論する必要がある。

#### (海中ロボットの制御)

海中ロボットの運動は、流体中における6自由度の運動となる上に、非線形な流体力の影響や運動モード間の干渉を考慮しなければならない。搭載機器の変更も念頭に置くと、海中ロボットの運動制御システムは柔軟で適応的であることが望ましい。海中ロボットの制御システムとして、しばしば登場するものにロバスタな制御手法であるSliding Mode Controlがある。Sliding Mode ControlはYoergerらによって発展させられた手法であり、海中ロボットの非線形なダイナミクスを直接扱うことができ、直感的にも分かりやすい。しかし、問題点としてチャタリングが挙げられ、海中ロボットのようにエネルギーが限られている場合は、様々な工夫がなされている。

ニューラルネットワークを用いた手法には、Yuhが行なっている直接的な調整則により、適応的にコントローラを生成する手法と、藤井らが行っている間接的な手法がある。Yuhの手法は、ロボットの運動から算出される制御誤差をもとにコントローラを調整するので、ロボットの正確なモデルを必要としない。藤井らの手法は、ロボットの運動モデルを内部に有し、運動モデルの評価値に基づいて誤差逆伝播法によりコントローラを調整する間接的な手法である。従って、運動モデルの精度が上がるほど、よりきめ細かなコントローラの生成が行える。これ



らの手法は、制御対象を用いた実験を並行して行い、実験から得られる制御誤差が必要である。そのため、海中ロボットの運動やサンプリングレート、コントロールレートとの兼ね合いによる適応性の限界が存在する。

筆者の提案する運動モデルを制御対象の代わりに導入するとこれらの制約がなくなり、処理の並列化及び高速化を行なったコントローラ調整法が「Imaginary Training」が実現できる。この手法の有効性も、運動モデルの場合と同様、実機の運動制御に適用し、実験においても良好に制御結果を示すことにより議論を行ってきた。更なる発展を考えた場合、コントローラの安定性や収束性などの議論が必要である。

#### (オンライン並列処理による外乱への適応)

海中ロボットの自律行動を実現するには、運動制御システムの適応性が重要な評価となる。ロボットの適応性は、未知な動作環境や情報に対する挙動を検討することにより判断できる。本論文で提案したコントロールシステム ITNN の適応性を検討するため、海中ロボットの運動制御システムとして搭載し、実験においてオンラインでの外乱処理を検討した。その結果、システム全体として良好に稼働すること及び、コンピュータの処理能力に応じた適応性が得られることを確認した。しかしながら、オンラインでの調整を評価にするには、調整が良好に行なわれない場合におけるシステム全体の安定性を議論する必要がある。実験結果を評価すると、誤差が小さいときに同じ適応則を用いて調整を進め場合、システムが不安定になる可能性があることが判明した。このことは、適応制御一般に問題となっており、オンラインでの安定性を補償する必要がある。適応制御の分野では、上記の問題に対し、不感帯法や $\sigma$ -修正法等を用いて対処しており、提案した ITNN においても適応可能であると思われる。新ら[109]は、適応制御のにおいて研究されているロバスト適応則を用いて、ニューラルネットワークの学習則の見直しを行ない、オンラインでの動作を保証する学習則を提案している。今後、適応制御理論とニューラルネットワークの融合による、安定した適応則の発展が重要となる。



## 第 8 章

### 結論

海中ロボットを開発するには、通信手段及び密度の乏しさや、外部環境把握が困難であること、その3次元的な運動等を考慮する必要がある。さらに、未知な動作環境において、自由に行動し目的を達成するには、得られた情報から状況を的確に判断し対処できる自律性が不可欠となる。海中ロボットの自律性を実現するには、様々な関連する技術を確立する必要があるが、その重要課題として、運動制御システムの開発が挙げられる。海中ロボットの運動は流体中での6自由度の運動となるうえに、複雑な形状を有することも考えられ、運動モード間の相互影響や非線形な流体力を考慮する必要がある。また、ミッションに依存する搭載の変更が考えられ、これに起因する運動特性の変化に対して適応的に対処できる運動モデル及び制御手法が必要となる。本論文では、ニューラルネットワークによる海中ロボットの運動の表現手法及び制御手法について検討を行なった。

ニューラルネットワークによる海中ロボットの運動モデル「Identification Network」は、モデル化が容易でない不確かな要素を含め、実験データから直接的に作成することを考えて提案した運動モデルである。システム同定の分野において用いられる差分方程式や状態方程式の構造を念頭において考案したモデルであり、同定の精度向上とモデル単体によるシミュレーション機能を実現するため、出力層及び中間層からの回帰的結合を有する新たな構造のネットワークを考案した。また、ニューラルネットワークの学習アルゴリズムである誤差逆伝播法は、最急降下法の1種であり、局所解の問題や学習回数、収束の判断などの不明確な要素がある。本論文では、運動モデルの学習過程を教示データの入出力関係に基づき4段階に分割し、学習の収束状況に応じて進めることにより学習の効率化を図った。さらに、得られたネットワークの信頼性を評価するため、入力値が既に学習した領域内に存在するかを判定し、得られた評価値に基づいて信頼性を出力随伴ネットを導入した。運動モデルと随伴ネットを組み合わせることにより、出力に対する信頼性の確保が可能である。

Identification Networkの特徴であるシミュレーション機能を運動制御システムへ応用することを考え、新たなコントローラ調整法「Imaginary Training」を提案した。Imaginary Trainingは、Identification Networkが制御対象と同等の動特性を有すると仮定し、シミュレーションの制御結果を評価し、誤差逆伝播法によりコントローラの結合荷重を調整する手法である。一般的に、コントローラの調整は、制御対象のモデルにはモデル化誤差やパラメータ誤差が存在するため、制御対象から得られる実験データの制御誤差から行う。本手法の運動モデルは、制御対象の実験データから直接構築しており、シミュレーションにおいて高速にコントローラの調整を行うことが可能である。



Imaginary Trainingが制御対象とは独立して動作できることを活かし、並列処理を念頭においたコントロールシステムITNN (Imaginary Training system with Neural Network) を提案した。ITNNは、Imaginary-World Part 及び Real-World Part の独立した処理プロセスから構成される。Imaginary-World Part では、実時間に依存せず Imaginary Training によるコントローラ調整と運動モデルの追加学習が行われ、非同期に Real-World Part のコントローラを更新する。ITNN の各処理プロセスは、非同期に独立して動作するので、プロセッサの処理能力の向上が直接コントローラ調整の高速化を実現する。

提案した運動モデル及びコントローラ調整法の有効性の検討を行うため、海中ロボットのテストベッドである PW45 の縦運動制御、汎用テストベッド Twin-Burger の方位角制御及び長期観測用ロボット R-one の方位角制御に適用した。実験結果から、

- ・ 精度の良い運動の同定、及び高速なコントローラの調整ができる。
- ・ 長周期外乱の影響は、運動特性の変化として運動モデル内に取り込まれ、コントローラが定常状態において外乱に相当する力を出力するように調整される。
- ・ 周期的な外乱の影響は、運動モデルによる表現が困難である。一方、コントローラが逆位相の操作量を出力するために、周期的な運動が現れない。

等を確認した。上記の結果は、運動特性の変化として表現できる外乱の推定ができることを示しており、ITNN に外乱推定機構を付加することにより、システムの適応性の向上が可能となる。

外乱の推定機構を付加し、外乱が存在する状況において、運動モデルの更新、コントローラの調整、実機の制御をオンラインで並列に処理する実験を行った。実験の結果から、システムが並列処理能力を有するシステムにおいて能力を発揮すること、学習の進行に伴ってコントローラの調整が進むこと、フィードバックコントローラと外乱推定機構を組み合わせにより、柔軟な制御が可能であること等を確認した。

これらの結果から、ニューラルネットワークを用いた運動の表現と制御の有効性が示された。提案したシステムは海中ロボットの運動制御システムとして十分な柔軟性と適応性を有すると結論する。

本論文の成果が、自律型海中ロボットの実現に貢献し、海洋の環境調査や自然のメカニズムの解明につながることを期待して、本論文の結びとする。



# Appendix

## 結合荷重一覽

## A. 運動モデルの結合荷重

## ・PW45

3章における Figs. 3-13~16 において用いた PW45 の縦運動に関する運動モデルの結合荷重を Table A-1 に示す。入力変数は、ピッチ角、深度、エレベータ切り角であり、ピッチ角速度、深度変化量を出力する。

Table A-1 Synaptic weights of dynamical model to represent the motion of PW45.  
Experimental data when  $\delta e$  is trimmed in 0.5Hz is used as teaching data.

		Unit Number of Hidden Layer									
		1	2	3	4	5	6	7	8	9	10
Input Layer	1	-0.2783	-0.0925	-0.2766	-0.0669	-0.0770	-0.2641	-0.2362	-0.2238	-0.0686	-0.2110
	2	-0.0381	0.0376	-0.0299	-0.0103	0.0433	-0.0926	0.0107	-0.1571	-0.0097	-0.1613
	3	0.0912	-0.2005	0.0914	-0.1171	0.1463	0.0644	0.1173	0.0119	-0.1165	-0.0245
Output Layer	1	1.3808	-2.8011	1.4592	-1.7200	2.5775	0.9020	1.9083	0.1721	-1.7210	-0.1963
	2	-0.1259	0.4405	-0.1372	0.2373	-0.3355	-0.0863	-0.1922	-0.0244	0.2388	0.0093
Rec. (Input)	1	0.0915	-0.4529	0.1080	-0.3149	0.3327	-0.0014	0.2001	-0.1276	-0.3147	-0.1788
	2	-0.5117	1.1289	-0.5373	0.6793	-0.9407	-0.3626	-0.6895	-0.1310	0.6794	0.0000
	3	0.1038	-0.4837	0.1201	-0.3336	0.3593	0.0045	0.2176	-0.1288	-0.3340	-0.1832
	4	-0.3408	0.7042	-0.3554	0.4131	-0.6006	-0.2543	-0.4462	-0.1186	0.4138	-0.0369
	5	0.2734	-0.9254	0.3025	-0.5990	0.7319	0.1025	0.4724	-0.1332	-0.6002	-0.2369
	6	0.0235	-0.2704	0.0341	-0.2029	0.1797	-0.0403	0.0952	-0.1244	-0.2033	-0.1546
	7	0.1698	-0.6595	0.1915	-0.4399	0.5081	0.0427	0.3194	-0.1311	-0.4399	-0.2050
	8	-0.0760	-0.0002	-0.0725	-0.0348	-0.0431	-0.0949	-0.0574	-0.1155	-0.0347	-0.1161
	9	-0.3413	0.7043	-0.3564	0.4135	-0.6003	-0.2544	-0.4470	-0.1177	0.4140	-0.0363
	10	-0.1238	0.1325	-0.1240	0.0481	-0.1504	-0.1212	-0.1303	-0.1125	0.0486	-0.0973
Thresh hold	hid	-0.1781	-0.0230	-0.1657	-0.0723	-0.0217	-0.2456	-0.1007	-0.3112	-0.0715	-0.3089
	out	0.0328	-0.1053	-	-	-	-	-	-	-	-

Figures 3-17-19 において用いた運動モデルの結合荷重を Tables A-2,3 に示す。ネットワークの構造は、Table A-1 に示した運動モデルと同様、入力変数として、ピッチ角、深度、エレベータ切り角を用い、ピッチ角速度、深度変化量を出力とした。

Table A-2 Synaptic weights of dynamical model to represent the motion of PW45.

Experimental data when  $\delta\epsilon$  is trimmed in 0.1Hz is used as teaching data and the difference type network is adopted as network model.

		Unit Number of Hidden Layer									
		1	2	3	4	5	6	7	8	9	10
Input Layer	1	2.7891	1.8915	2.5633	3.3038	0.1417	3.0574	1.0334	3.4820	4.0510	1.5524
	2	0.9325	1.7572	3.8546	1.4373	0.8235	2.4199	1.4746	2.0517	2.3088	2.1743
	3	-1.7756	-2.8664	-2.2213	-3.3962	2.7871	-1.2543	-0.0907	-3.5368	-3.3466	-1.6933
Output Layer	1	-0.9193	-1.0496	0.2504	0.0400	1.9076	-0.1954	0.1038	1.1188	0.3647	0.7926
	2	-5.0986	3.1791	-0.7745	-0.5016	-0.6643	-0.3733	-1.3662	-1.4738	-4.1900	1.2528
Rec. (Input)	1	3.3953	-0.3872	0.1612	1.3014	-0.1317	1.4275	-0.4142	0.3366	0.4943	-0.5509
	2	-1.0696	0.9765	1.2232	-0.1241	-1.8787	1.5091	-0.5823	0.0410	0.3995	4.7343
	3	0.6686	-1.1377	7.0905	1.1160	-0.2701	2.9970	-0.4738	-0.4410	-0.7496	-1.9161
	4	1.1122	1.0309	2.1518	5.3656	0.3277	1.3315	-2.6550	1.7523	0.0652	0.3928
	5	-0.6183	-0.6822	-1.7698	-1.4972	1.3746	-1.5385	1.0284	-1.6434	-1.9849	-1.2993
	6	0.6006	-0.9632	2.1060	-0.1211	-0.2579	6.7327	-1.0336	-1.9308	-1.5490	-2.4728
	7	-0.5451	0.8305	-0.6912	-1.4890	0.4671	-1.0707	3.8184	1.9099	0.3657	0.0289
	8	-0.0171	1.1081	1.2872	3.3257	0.7318	0.5753	3.5501	5.7371	1.1115	1.0558
	9	-1.8226	1.0390	1.0108	1.5873	0.0993	0.4780	2.7282	4.4339	6.8663	1.4922
	10	-0.3359	1.0929	-0.4678	-0.8451	0.3983	-0.5299	1.4518	-0.5565	-0.5564	5.7418
Thresh hold	hid	-2.0018	-2.0634	-4.5896	-2.3862	-2.2601	-3.1145	-1.0236	-2.5811	-2.6553	-2.0052
	out	-2.5262	5.4319	-	-	-	-	-	-	-	-



Table A-3 Synaptic weights of dynamical model to represent the motion of PW45.  
 Experimental data when  $\delta e$  is trimmed in 0.1Hz is used as teaching data and the  
 difference type network is NOT adopted as network model.

		Unit Number of Hidden Layer									
		1	2	3	4	5	6	7	8	9	10
Input Layer	1	-3.5701	-3.8638	-3.6985	-3.5135	-3.6454	-0.0631	-0.0636	-0.2236	0.0528	-0.1000
	2	-0.0545	0.0670	-0.0159	-0.0444	-0.0427	3.3599	3.3373	3.8553	2.7644	3.6795
	3	-0.2192	-0.0680	-0.2176	-0.1936	-0.2241	-0.0100	-0.0167	0.1336	-0.1660	0.0337
Output Layer	1	-0.7381	-1.7172	-1.2215	-0.5963	-0.9882	-	-	-	-	-
	2	-	-	-	-	-	2.4268	2.4030	2.5784	2.2966	2.8992
Rec. (Input)	1	-0.0186	-0.2913	-0.1821	0.0706	-0.1198	-	-	-	-	-
	2	0.1249	0.0452	0.0626	0.1684	0.0812	-	-	-	-	-
	3	0.0556	-0.1335	-0.0638	0.1240	-0.0200	-	-	-	-	-
	4	-0.0481	-0.3372	-0.2220	0.0469	-0.1555	-	-	-	-	-
	5	0.0214	-0.2097	-0.1198	0.1006	-0.0668	-	-	-	-	-
	6	-	-	-	-	-	0.2344	0.2269	-0.1777	-0.3098	0.3503
	7	-	-	-	-	-	0.2168	0.2092	-0.1702	-0.3050	0.3277
	8	-	-	-	-	-	-1.1169	-1.1266	1.5455	0.6493	-1.0260
	9	-	-	-	-	-	-0.8190	-0.8329	0.9124	0.1350	-0.6600
	10	-	-	-	-	-	0.5941	0.5806	-0.2634	-0.3603	0.7928
Threshold	hid	1.0426	1.7205	1.4213	0.9162	1.2395	-2.5871	-2.5833	-1.3216	-1.1720	-2.8327
	out	1.7808	-4.6084	-	-	-	-	-	-	-	-

・Twin-Burger

Figure 3-22 に示したTwin-BurgerのYaw運動に関する運動モデルの結合荷重をTable A-4に示す。入力変数は角速度及び操作量であり、次の時間ステップの角加速度を出力する。また、2号機の運動モデルの結合荷重を併せて示す。

Table A-4a Synaptic weights of dynamical model to represent yawing motion of Twin-Burger.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	6.8269	-0.9976	-1.2679	-1.4881	-1.6212
	2	-4.9902	-3.0148	-1.5683	-1.8578	-1.9244
Output Layer	1	-1.8465	1.3848	1.6651	-0.3401	-1.1897
Rec. (Input)	1	3.6900	0.3367	1.5083	-1.8973	-2.0609
	2	0.0805	-0.1266	-0.1392	-1.2044	-1.2920
	3	-0.0857	-0.1546	-0.1528	-1.1938	-1.2813
	4	-0.8179	0.0702	0.0836	0.4876	0.5805
	5	-0.5128	0.0700	0.0852	0.6846	0.7874
Thresh hold	hid	-2.5116	-1.2048	0.7300	-4.5265	-4.9892
	out	0.0244	-	-	-	-

Table A-4b Synaptic weights of dynamical model to represent yawing motion of Twin-Burger 2.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	7.1872	-0.7615	-0.6487	-1.4897	-1.6242
	2	-3.6215	-4.5081	-1.8066	-1.8589	-1.9267
Output Layer	1	-0.7874	4.9322	-0.2034	-0.3306	-1.1846
Rec. (Input)	1	3.2473	1.1643	2.2967	-1.8989	-2.0639
	2	-0.1557	1.8386	-0.0286	-1.2049	-1.2930
	3	0.0651	0.9769	0.0849	-1.1956	-1.2846
	4	-0.8194	0.0719	0.0855	0.4876	0.5805
	5	-0.5136	0.0709	0.0862	0.6846	0.7874
Thresh hold	hid	-2.1912	-0.0556	1.4125	-4.5297	-4.9953
	out	-1.6735	-	-	-	-

Figure 3-23に示したTwin-BurgerのSurge運動に関する運動モデルの結合荷重をTable A-5に示す。入力変数は前進速度及び操作量であり、次の時間ステップの加速度を出力する。同様に、2号機の運動モデルの結合荷重を併せて示す。

Table A-5a Synaptic weights of dynamical model to represent surging motion of Twin-Burger.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.4497	-2.4505	-2.4540	-2.4477	-2.4467
	2	0.8483	0.8526	0.8424	0.8540	0.8525
Output Layer	1	1.4636	1.4654	1.4692	1.4634	1.4606
Rec. (Input)	1	-0.5787	-0.5790	-0.5781	-0.5785	-0.5779
	2	-0.5788	-0.5785	-0.5784	-0.5790	-0.5778
	3	-0.5775	-0.5782	-0.5777	-0.5773	-0.5768
	4	-0.5782	-0.5795	-0.5789	-0.5788	-0.5784
	5	-0.5794	-0.5799	-0.5794	-0.5790	-0.5787
Thresh hold	hid	-1.6932	-1.6930	-1.6947	-1.6922	-1.6902
	out	-0.4456	-	-	-	-

Table A-5b Synaptic weights of dynamical model to represent surging motion of Twin-Burger 2.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.0151	-2.0092	-2.0335	-1.9999	-2.0009
	2	1.2159	1.2260	1.1958	1.2343	1.2314
Output Layer	1	0.9377	0.9429	0.9358	0.9444	0.9396
Rec. (Input)	1	-0.6643	-0.6649	-0.6637	-0.6645	-0.6636
	2	-0.6646	-0.6645	-0.6642	-0.6651	-0.6637
	3	-0.6625	-0.6636	-0.6627	-0.6627	-0.6621
	4	-0.6642	-0.6658	-0.6648	-0.6651	-0.6646
	5	-0.6655	-0.6663	-0.6655	-0.6655	-0.6650
Thresh hold	hid	-2.2271	-2.2238	-2.2396	-2.2184	-2.2167
	out	-0.2931	-	-	-	-



Figure 3-24に示したTwin-BurgerのSway運動に関する運動モデルの結合荷重をTable A-6に示す。入力変数は横方向への速度及び操作量であり、次の時間ステップの加速度を出力する。同様に、2号機の運動モデルの結合荷重を併せて示す。

Table A-6a Synaptic weights of dynamical model to represent swaying motion of Twin-Burger.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.4497	-2.4505	-2.4540	-2.4477	-2.4467
	2	0.8483	0.8526	0.8424	0.8540	0.8525
Output Layer	1	1.4636	1.4654	1.4692	1.4634	1.4606
Rec. (Input)	1	-0.5787	-0.5790	-0.5781	-0.5785	-0.5779
	2	-0.5788	-0.5785	-0.5784	-0.5790	-0.5778
	3	-0.5775	-0.5782	-0.5777	-0.5773	-0.5768
	4	-0.5782	-0.5795	-0.5789	-0.5788	-0.5784
	5	-0.5794	-0.5799	-0.5794	-0.5790	-0.5787
Thresh hold	hid	-1.6932	-1.6930	-1.6947	-1.6922	-1.6902
	out	-0.4456	-	-	-	-

Table A-6b Synaptic weights of dynamical model to represent swaying motion of Twin-Burger 2.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	3.0040	3.0298	3.0791	3.0704	3.2178
	2	-0.8574	-0.8404	-0.8134	-0.8235	-0.7345
Output Layer	1	-0.3432	-0.3713	-0.4248	-0.4091	-0.5584
Rec. (Input)	1	-0.7207	-0.7187	-0.7155	-0.7186	-0.7125
	2	-0.7193	-0.7165	-0.7139	-0.7172	-0.7100
	3	-0.7154	-0.7136	-0.7102	-0.7127	-0.7052
	4	-0.7163	-0.7150	-0.7116	-0.7144	-0.7074
	5	-0.7087	-0.7062	-0.7018	-0.7046	-0.6946
Thresh hold	hid	-1.1467	-1.1342	-1.1148	-1.1242	-1.0685
	out	0.5867	-	-	-	-

Figure 3-25 に示した Twin-Burger の Heave 運動に関する運動モデルの結合荷重を Table A-7 に示す。入力変数は深度変化速度及び操作量であり、次の時間ステップの加速度を出力する。同様に、2号機の運動モデルの結合荷重を併せて示す。

Table A-7a Synaptic weights of dynamical model to represent heaving motion of Twin-Burger.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	0.4778	-1.2971	-1.2702	-2.8549	-3.0652
	2	0.4598	2.7812	0.4495	-1.3283	-0.2686
Output Layer	1	2.8601	-0.6186	2.3889	1.9694	1.3562
Rec. (Input)	1	0.6010	-0.7367	1.1180	0.4622	-0.0266
	2	-0.8047	0.4727	-0.9902	-0.2800	-0.1246
	3	-0.2182	-0.3392	0.2700	0.1117	-0.2622
	4	-0.0833	-0.9225	0.3429	0.5131	0.2728
	5	-0.1687	-0.9681	0.1040	0.3766	0.2867
Thresh hold	hid	-0.6475	-3.7910	-0.9439	-0.0775	-0.7225
	out	-2.6075	-	-	-	-

Table A-7b Synaptic weights of dynamical model to represent heaving motion of Twin-Burger 2.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.8109	-2.6885	-4.0750	-2.8457	-2.8625
	2	1.0565	1.2089	1.1934	1.0213	1.0150
Output Layer	1	-0.7480	-0.9548	1.8280	-0.7106	-0.7068
Rec. (Input)	1	-0.8510	-0.8152	-1.0219	-0.8625	-0.8677
	2	-0.8463	-0.8044	-1.0307	-0.8599	-0.8652
	3	-0.9504	-1.0019	-0.2076	-0.9512	-0.9561
	4	-0.8492	-0.8151	-1.0205	-0.8611	-0.8664
	5	-0.8472	-0.8123	-1.0205	-0.8581	-0.8636
Thresh hold	hid	-0.4927	-0.4694	1.3680	-0.4983	-0.4944
	out	-0.2941	-	-	-	-

・ R-one robot

Figures 3-27-29 に示される R-one robot の方位角に関する運動モデルの結合荷重を Table A-8 に示す。入力変数は、方位角速度、ラダー切り角、メインスラストへの指示値であり、出力変数は方位角速度である。

Table A-8 Synaptic weights of dynamical model to represent heading motion of R-one robot

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	0.4778	-1.2971	-1.2702	-2.8549	-3.0652
	2	0.4598	2.7812	0.4495	-1.3283	-0.2686
	3	2.8601	-0.6186	2.3889	1.9694	1.3562
Output Layer	1	2.8601	-0.6186	2.3889	1.9694	1.3562
Rec. (Input)	1	0.6010	-0.7367	1.1180	0.4622	-0.0266
	2	-0.8047	0.4727	-0.9902	-0.2800	-0.1246
	3	-0.2182	-0.3392	0.2700	0.1117	-0.2622
	4	-0.0833	-0.9225	0.3429	0.5131	0.2728
	5	-0.1687	-0.9681	0.1040	0.3766	0.2867
Thresh hold	hid	-0.6475	-3.7910	-0.9439	-0.0775	-0.7225
	out	-2.6075	-	-	-	-



## B. コントローラの結合荷重

## ・PW45

PW45の縦運動制御に用いた初期コントローラ (Fig. 5-5) の結合荷重を Table B-1a に、調整後のコントローラ (Fig. 5-8) の結合荷重を Table B-1b に示す。入力変数は、ピッチ角、ピッチ角速度、深度、深度変化速度における目標値との誤差及び、1時間ステップ前のエレベータ切り角である。操作量であるエレベータ切り角を出力する。

Table B-1a Synaptic weights of controller network to control longitudinal motion of PW45 (initialized controller).

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.3097	-2.1756	-2.3624	-2.3648	-4.0712
	2	-1.9879	-1.1590	-4.0723	-3.2391	-3.0317
	3	3.8073	4.3860	3.0116	3.2807	6.5768
	4	-0.4541	-0.2920	-0.4322	-0.4743	0.7421
	5	0.4655	-0.3190	3.1922	2.0760	0.9738
Output Layer	1	3.1138	3.3330	3.7839	3.3345	4.6632
Threshhold	hid	-2.3288	-1.6370	-3.1598	-2.8981	0.9613
	out	-5.2254	-	-	-	-

Table B-1b Synaptic weights of controller network to control longitudinal motion of PW45 (adjusted controller).

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-2.3894	-2.3784	-2.3961	-2.4023	-4.2853
	2	-2.0282	-1.2405	-4.0983	-3.2641	-3.0728
	3	3.7316	4.1987	2.9760	3.2427	6.4006
	4	-0.5154	-0.4373	-0.4662	-0.5084	0.6302
	5	0.4321	-0.3791	3.1547	2.0452	0.9367
Output Layer	1	3.0704	3.2152	3.7650	3.3130	4.2288
Threshhold	hid	-2.4511	-1.9271	-3.2263	-2.9653	0.7294
	out	-5.7244	-	-	-	-

・Twin-Burger

Twin-Burger のYaw 運動に用いた初期コントローラ (Fig. 5-11) 及び調整後のコントローラ (Figs. 12,14,15) の結合荷重を Tables B-2a,2b に示す。入力変数は、方位角 (Yaw 角) 及び角速度の目標値への誤差量と、1 時間ステップ前の操作量であり、操作量として Yaw モーメントを出力する。

Table B-2a Synaptic weights of controller network to control yawing motion of Twin-Burger (initialized controller).

Yaw		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-5.2300	-4.9004	-5.2190	0.1481	-4.0049
	2	-0.2205	-0.1969	-0.1142	-2.8308	0.0373
	3	-13.2842	-12.6049	-13.2282	-8.8405	-11.3420
Output Layer	1	-3.3735	-3.2945	-3.0645	-3.1397	-3.3048
Threshh old	hid	2.9613	2.9648	3.0099	8.4032	3.7772
	out	3.0382	-	-	-	-

Table B-2b Synaptic weights of controller network to control yawing motion of Twin-Burger (adjusted controller).

Yaw		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-5.8281	-5.6046	-5.8242	-7.0205	-5.4977
	2	-0.8080	-0.8723	-0.7064	-7.0663	-1.2473
	3	-13.3487	-12.6492	-13.2893	-2.4100	-11.1576
Output Layer	1	-3.0611	-2.9414	-2.7193	-8.7013	-2.6771
Threshh old	hid	2.0608	1.9792	2.1157	9.7921	2.3025
	out	7.1989	-	-	-	-

Twin-BurgerのSurge、Sway、Heave運動に関するコントローラ (Figs. 6-25~27) の結合荷重を Tables B-3~5 に示す。入力変数は位置及びその速度成分の目標値に対する誤差量及び1時間ステップ前の操作量であり、各運動モードに関する力を出力する。

Table B-3 Synaptic weights of controller network to control surging motion of Twin-Burger.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-6.1204	-5.8617	-6.1044	-4.6561	-5.5892
	2	-1.4192	-1.4700	-1.3029	-14.0167	-1.8666
	3	-13.4698	-12.7573	-13.4025	-0.5547	-11.0996
Output Layer	1	-3.0840	-2.9356	-2.7131	-14.8778	-2.4702
Threshold	hid	1.4417	1.3423	1.4701	9.7056	1.5413
	out	8.4909	-	-	-	-

Table B-4 Synaptic weights of controller network to control swaying motion of Twin-Burger.

Sway		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-6.1204	-5.8618	-6.1044	-4.8190	-5.5894
	2	-1.4192	-1.4701	-1.3030	-13.8258	-1.8668
	3	-13.4699	-12.7574	-13.4025	-0.9934	-11.0997
Output Layer	1	-3.0840	-2.9356	-2.7130	-15.0001	-2.4700
Threshold	hid	1.4415	1.3421	1.4699	10.0247	1.5409
	out	8.4675	-	-	-	-



Table B-5 Synaptic weights of controller network to control heaving motion of Twin-Burger.

Heave		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-6.0246	-5.7745	-6.0156	-8.9923	-5.5123
	2	-1.0497	-1.1239	-0.9608	-9.0187	-1.5474
	3	-13.4262	-12.7150	-13.3612	-1.1436	-11.0555
Output Layer	1	-3.3188	-3.1612	-2.9628	-13.0700	-2.7135
Threshold	hid	1.9882	1.8530	1.9760	9.7632	2.0103
	out	7.3745	-	-	-	-

・ R-one robot

R-one robot の方位角運動に関するコントローラ (Figs. 5-18~20) の結合荷重を Table 2-6 に示す。入力変数は、方位角及び角速度の目標値への誤差量、1 時間ステップ前の操作量、メインスラストへの指令値であり、ラダー切り角を出力する。

Table B-6 Synaptic weights of controller network to control heading motion of R-one robot.

		Unit Number of Hidden Layer				
		1	2	3	4	5
Input Layer	1	-6.1116	-5.8563	-6.1005	-5.0334	-5.5885
	2	-1.4028	-1.4600	-1.2958	-13.6001	-1.8654
	3	2.0237	1.0145	0.5104	-0.4040	-1.9983
	4	-13.4662	-12.7553	-13.4012	-0.7264	-11.0993
Output Layer	1	-3.0973	-2.9428	-2.7184	-14.9880	-2.4710
Threshhold	hid	1.4694	1.3594	1.4822	10.2596	1.5434
	out	8.3433	-	-	-	-

## 謝辞

本論文は、東京大学工学部船舶海洋工学科、及び同大学院工学系研究科船舶海洋工学科専攻における約6年間、多くの方々のご指導、ご協力があったはじめてかたちを成すことができました。本論文をまとめるにあって、お世話になった方々の名前を挙げて感謝の意を表します。

東京大学生産技術研究所浦環教授には、大学院及び研究生5年間半にわたり、指導教官としてご指導いただき、公私ともにお世話になりました。研究の過程や普段からの会話においても常に有り難い助言を頂きました。常に身近に接して頂けるので、研究室においても自由にのびのびを研究を進めることができました。浦研究室で過ごした経験は、私の人生において貴重な宝となるでしょう。

東京大学生産技術研究所能勢義昭助手、坂巻隆技術官には、研究室での生活や公私にわたって、つねに気を使っていたいただき、研究が進めやすい環境を整えて頂きました。また、実験においても様々な便宜を図って頂き、研究に集中することができました。

秘書である杉松治美女史には、研究室での生活で色々お世話になりました。

理化学研究所藤井輝夫氏、明治大学工学部黒田洋司講師は、大学院時代からの良き先輩であり、研究に対する姿勢や考え方等、海外における学会等、様々なことについて、公私にわたってご指導を頂きました。

東京大学大学院博士課程3年の須藤拓氏は、一番身近な方であり、コンピュータやネットワークの整備など、研究には欠かせないことについて面倒をみていただきました。

さらに、浦研究室のメンバーである、海洋科学技術センターの川口勝義氏、博士課程3年の荒牧浩二氏、林雲聰氏、博士課程2年のバラスリヤ夫妻、修士課程2年の高井基行氏、川野洋氏、修士課程1年の鷺野茂氏、学部時代の同級生で三井造船から修士課程に国内留学している松村竹実氏、中国から留学されている張銘鈞先生、日産自動車に就職した折出光宏氏にも普段からお世話になりました。

同級の渡辺啓介氏は良き仲間であり、競争相手でもある。彼に影響を受けてここまで研究を続けてきたと言っても過言ではなく、感謝しています。

修士課程において研究室の同級であった千葉氏、木下研の白枝氏、都井研の清末氏には生研の生活においてお世話になりました。



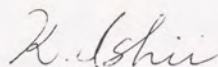
東京大学工学部大坪英臣教授には、学部時代において研究の手ほどきをして頂きました。

東京大学工学部小山健夫教授、吉田宏一郎教授、大和裕幸助教授、鈴木英之助教授には、論文作成にあたり貴重な御意見を頂きました。

また、(株)トリックスの方々や、三井造船昭島研究所の日下氏にはTwin-Burger2の開発及び実験において、大変お世話になりました。

最後になりますが、私を支えてくれた両親の石井昌雄、美智子、そして妻のまゆみに心から感謝の意を表して謝辞とします。

1996.6.21 石井和男

A handwritten signature in cursive script, likely reading 'K. Ishii', written in dark ink on a light-colored background.

## 参考文献一覧

- [1] 例えば(社)日本造船学会海中技術専門委員会編、“海中技術一般”、成山堂書店
- [2] 白山義久、“生物多様性を深海底に見る”、科学、vol. 65, no. 11, pp. 766-774
- [3] B. H. ロビンソン、“あやしく光る海洋生物”、日経サイエンス、vol. 25, no. 9, pp. 48-58
- [4] 末広潔、“ODP 深海底学術掘削と孔内計測”、日本造船学会誌、vol. 775, pp. 18-23
- [5] 平啓介、“世界海洋観測システム(GOOS)の構築に向けて”、日本造船学会誌、vol. 775, pp. 51-56, 1994
- [6] 藤本博巳、“中央海嶺系に関する国際研究協力計画インターリッジ”、日本造船学会誌、vol. 775, pp. 57-60, 1994
- [7] 藤本博巳、“大西洋中央海嶺の断層帯”、科学、vol. 65, no. 11, pp. 775-783
- [8] 浦環、高川真一、“海中ロボット総覧”、成山堂書店
- [9] 徳山英一、山本富士夫、平朝彦、“IZANAGI による海底の面像化”、日本造船学会誌、vol. 775, pp. 42-46, 1994
- [10] “Autopilots of the deep”、IEEE SPECTRUM, no. 8, pp. 38-42, 1994
- [11] 浦環、大坪新一郎、“航行型無索無人潜水艇に関する研究(その1 グライディング航行の研究)”、日本造船学会論文集、vol. 162, pp. 117-124, 1987
- [12] 前田久明他、“無索無人潜水艇に働く線形流体力及び操縦応答に関する研究”、日本造船学会論文集、vol. 164, pp. 211-220, 1988
- [13] D.E. Rumelhart, J.L. McClelland, The PDP research Group, “Parallel Distributed Processing”、Cambridge, MA: The MIT Press, 1986
- [14] K.S. Narendra, K. Parthasarathy, “Identification and Control of Dynamical Systems Using Neural Networks”、IEEE Trans. of Neural Networks, vol. 1, no. 1, pp. 4-27, 1990
- [15] 五味裕章、川人光男、“生体運動制御系における内部モデルを利用した運動司令の生成”、第4回インテリジェント・システム・シンポジウム講演論文集、pp. 155-160
- [16] T. Kohonen, “Emergence of Invariant-Feature Detectors in Self-Organization”、Computational Intelligence II, IEEE Press, pp. 17-31, 1995
- [17] E. Oja, J. Karhunen, “Signal Separation by Nonlinear Hebbian Learning”、Computational Intelligence II, IEEE Press, pp. 83-97, 1995
- [18] 斎藤史倫、福田敏男、“強化学習による実ロボットの運動制御”、日本ロボット学会誌、vol. 13, no. 1, pp. 82-88, 1995

- [19] J.G. Bellingham, T. Consi and R. Beaton, " Keeping Layered Control Simple", Proc. of AUV'90, pp. 3-9, 1990
- [20] J.G. Bellingham et al., "Hyberbolic Acoustic Navigation for Underwater Vehicles", Proc. of AUV'92
- [21] J.G. Bellingham et al., " A Second Generation Survey AUV", Proc. of AUV'94, pp. 148-155
- [22] A.M. Bradley, W.E.Jr. Terry, " A Coherent Approach to Instrumentation Intercommunication and Testing Using SAIL", Proc. of 3rd Oceanographic Data Systems, 1983
- [23] 例えば、柴田嵩徳、福田敏男、" 人工生命の近未来"、時事通信社、1995
- [24] D.K. Atwood et al., " An Acoustic Navigation System for Multi-Vehicle Operations", Proc. of 9th UUST, pp.202-208, 1995
- [25] A.A. Bennett, J.J. Leonard, J.G. Bellingham, " Bottom Following for Survey-Class Autonomous Underwater Vehicles", Proc. of 9th UUST, pp. 327-336, 1995
- [26] Underwater News & Technology, March/April, pp. 28-29, 1995
- [27] S.M. Smith, " An Approach to Intellignet Distributed Control for Autonomous Underwater Vehicles", Proc. of AUV'94, pp. 105-111, 1994
- [28] " Commercial AUVS ", Underwater News & Technology, March/April, pp. 18-19, 1994
- [29] S.M. Smith et al., " The Ocean Explorer AUV: A Modular Platform For Coastal Oceanography", Proc. of 9th UUST, pp. 67-76, 1995
- [30] D.R. Blidberg, " Guidance Control Architecture for the EAVE Vehicle", IEEE Journal of Oceanic Engineering, vol.11, no. 4, pp. 449-461, 1986
- [31] S. G. Chappell et al., " Acoustic Communication Between Two Autonomous Underwater Vehicles", Proc. of AUV'94, pp. 462-469, 1994
- [32] E.H. Turner, S.G. Chappell, S.A. Valcourt, " COLA: A Language to Support Communication between Multiple Cooperating Vehicles", Proc. of AUV'94, pp. 309-316, 1994
- [33] S.M. Zanolli, S.G. Chappell, " A Dual Abstraction Level Obstacle Avoidance Module for an Autonomous Underwater Vehicle", Proc. of 9th UUST, pp. 317-326, 1995
- [34] D.R. Yoerger, A.M. Bradley, B.B. Walden, " The Autonomous Benthic Explorer (ABE): An AUV Optimized for Deep", Proc. of 7th UUST, pp. 60-70, 1991
- [35] H. Singh et al., " Sonar Mapping with the Autonomous Benthic Explorer", Proc. of 9th UUST, pp. 367-375, 1995
- [36] 桑田守, " GYRO/AUTOPILOT の技術動向", 日本造船学会誌, vol.802, pp. 3-9, 1996



- [37] D. Yoerger et al., "Near-Bottom Magnetic Surveys of the Coaxial Ridge Segment Using the Autonomous Benthic Explorer Survey Vehicle", RIDGE Events, February, pp. 5-9, 1996
- [38] D. Yoerger et al., "Surveying a Subsea Lava Flow Using the Autonomous Benthic Explorer (ABE)", Proc. of IARP'96, PP. 1-21
- [39] B. Butler, "Field Trials of The Theseus AUV", Proc. of 9th UUST, pp. 6-15, 1995
- [40] A.J. Healey and D.B. Marco, "Experimental Verification of Mission Planning by Autonomous Mission Execution and Data Visualization Using The NPS AUV II," Proc. of AUV'92, pp. 65-72, 1992.
- [41] A.J. Healey et al., "Tactical / Execution Level Coordination for Hover Control of the NPS AUV II using Onboard Sonar Servoing", Proc. of AUV'94, pp. 129-138, 1994
- [42] Per Egeskov, Andres Bjerrum, Antonio Pascoal, Carlos Silvestre, "Design, Construction and Hydrodynamic Testing of the AUV MARIUS", Proc. of AUV'94, pp. 199-207, 1994
- [43] Xingsong Jiang, Xisheng Feng, Liang Zhao, "Research & Development of New Control System of AUV", Proc. of 9th UUST, pp. 62-65, 1995
- [44] Richard Uhrich, James Walton, "Supervisory Control of Untethered Undersea Systems: A New Paradigm Verified", Proc. of 9th UUST, pp. 1-5, 1995
- [45] Brian Bourgeois, Mike Harris, "The NRL "ORCA" Oceanographic Survey Vessel", Proc. of 9th UUST, pp. 16-26, 1995
- [46] Brian Bourgeois, Mike Harris, "The U.S. Navy's First Generation ORCA", Sea Technology, November, pp. 25-33, 1995
- [47] T.Ura, "Free Swimming Vehicle PTEROA for Deep Sea Survey," Proc. of ROV'89, pp. 263-268, 1989
- [48] 藤井輝夫、浦環、黒田洋司, "自己生成型ニューラルネットコントローラシステムの開発と潜水機の運動制御への適用", 日本造船学会論文集, vol. 168, pp. 275-281, 1990
- [49] K. Katsuyoshi et al., "Development and Sea Trials of a Shuttle Type AUV "ALBAC"", Proc. of 8th UUST, pp. 7-13, 1993
- [50] 川口勝義他, "シャトル型海中ロボットの開発と実海域試験", 日本造船学会論文集, vol. 178, pp. 657-665
- [51] T.Fujii, T.Ura, Y.Kuroda: "Mission Execution Experiment with a Newly Developed AUV The Twin-Burger", Proc. of 8th UUST, pp. 92-105, 1993
- [52] T.Fujii et al., "Development of a Versatile Test-Bed "Twin-Burger toward Realization of Intelligent Behaviors of Autonomous Underwater Vehicles," Proc. of IEEE OCEANS'93, pp. 186-191, 1993

- [53] 藤井輝夫, "海中ロボットの知的行動に関する研究", 東京大学博士論文, 1993
- [54] 浦環, "無索無人機による海洋調査の可能性を拓く", 日本造船学会誌, vol. 775, pp. 9-14, 1994
- [55] Y. Ito et al., "Cable Tracking for Autonomous Underwater Vehicle", Proc. of AUV'94, pp. 218-224, 1994
- [56] R.L. Marks, S.M. Rock, M.J. Lee, "Real-Time Video Mosaicking of the Ocean Floor", IEEE Journal of Oceanic Engineering, vol. 20, no. 3, pp. 229-241, 1995
- [57] H.H. Pien, D.E. Custafson, W.F. Bonnice, "An AUV Vision System for Target Detection and Precise Positioning", Proc. of AUV'94, pp. 36-43, 1994
- [58] B.A.A.P. Balasuriya, T. Fujii, T. Ura, "Underwater Pattern Observation for Positioning and Communication of AUVs", Proc. of 9th UUST, pp. 193-201, 1995
- [59] Y. Kuroda, T. Ura, K. Aramaki, "Vehicle Control Architecture for Operating Multiple Vehicles", Proc. of AUV'94, pp. 323-329, 1994
- [60] M.S. トリアンタフィロ, G.S. トリアンタフィロ, "ロボット・マグロ", 日経サイエンス, vol. 25, no. 5, pp. 94-102, 1995
- [61] D.S. Barrett, M.S. Triantafyllou, "The Design of a Flexible Hull Undersea Vehicle Propelled by an Oscillating Foil", Proc. of 9th UUST, pp. 111-123, 1995
- [62] J.C. Jalbert S. Kasin J. Ayers, "Design Considerations and Experiments of a Biologically Based Undulatory Lamprey AUV", Proc. of 9th UUST, pp. 124-138, 1995
- [63] T. Ura, T. Fujii, Y. Nose and Y. Kuroda, "Self-Organizing Control System for Underwater Vehicles", Proc. of OCEANS'90, pp. 76-81, 1990
- [64] 藤井輝夫他, "自己生成型ニューラルネットコントローラシステムの開発と潜水機の運動制御への適用(その2:フォワードモデルの改良と無索テストベッドによる実験)", 日本造船学会論文集, vol. 169, pp. 477-486, 1991
- [65] T. Fujii and T. Ura, "SONCS: Self-Organizing Neural-Net-Controller System for Autonomous Underwater Robots", Proc. IEEE/INNS IJCNN'91, pp. 1973-1982, 1991
- [66] 藤井輝夫, 浦環, "ニューラル・ネットを用いた水中航行体の制御", 第32回自動制御連合講演会予稿集, pp. 303-306, 1989
- [67] T. Suto, T. Ura, "Unsupervised Learning System for Vehicle Guidance Constructed with Neural Network", Proc. of 7th UUST, pp. 203-212, 1991
- [68] T. Suto, T. Ura, "Unsupervised Learning System for Vehicle Guidance Constructed with Neural Network (2nd report: Modification of Forward Model and Adaptation Process)", Proc. of 8th UUST, pp. 222-230, 1993




- [69] 浦環、須藤拓、"自己訓練による海中ロボットの定高度航行"、日本造船学会論文集、vol. 171、pp. 581-586、1992
- [70] 浦環、須藤拓、"自己訓練による海中ロボットの定高度航行(その2:フォワードモデルの改良)"、日本造船学会論文集、vol. 174、pp. 917-924、1993
- [71] J. Yuh、"A Neural Net Controller For Underwater Robotic Vehicles"、IEEE J. Ocean. Eng.、vol. 15、no. 3、pp. 161-166、1990
- [72] J. Yuh、"Leaning Control for Underwater Robotic Vehicles"、IEEE Control Syst. Mag.、vol. 15、no. 2、pp. 39-46、1994
- [73] R.S. Burns、"The Use of Artificial Neural Networks for the Intelligent Optimal Control of Surface Ships"、IEEE Journal of Oceanic Eng.、vol. 20、no. 1、pp. 65-72、1995
- [74] 小川原陽一、岩本才次、吉村学、"風外乱補償機能を付加した船舶操縦運動の学習型フィードフォワード制御方式の基礎的検討"、日本造船学会誌、vol. 178、pp. 321-328
- [75] I. Yamamoto et al.、"Propulsion System with Flexible/Rigid Oscillating Fin"、IEEE Journal of Oceanic Eng.、vol. 20、no. 1、pp. 23-30、1995
- [76] I. Yamamoto et al.、"Proc. of IEEE/ICNN'95、
- [77] T.K.Y. Lo、H. Leung、J. Litva、"Artificial Neural Network for AOA Estimation in a Multipath Environment Over the Sea"、IEEE Journal of Oceanic Eng.、vol. 19、no. 4、pp. 555-562、1994
- [78] J.C. Park、R.M. Kennedy、"Remote Sensing of Ocean Sound Speed Profiles by a Perceptron Neural Network"、IEEE Journal of Oceanic Eng.、vol. 21、no. 2、pp. 216-224、1996
- [79] A.J. Healey、"A Neural Network Approach to Failure Diagnostics for Underwater Vehicles"、Proc. of AUV'92、pp. 131-134、1992
- [80] M. Takai、T. Fujii、T. Ura、"A Model Based Diagnosis System for Autonomous Underwater Vehicles Using Artificial Neural Network"、Proc. of 9th UUST、pp. 243-252、1995
- [81] V.W. Porto、D.B. Fogel、"Neural Network Techniques for Navigation of AUVs"、Proc. of AUV'90、pp. 137-141、1990
- [82] 浦環、石井和男、"ニューラルネット形成時の学習領域の記憶と知識獲得"、日本造船学会論文集、vol. 171、pp. 587-593
- [83] 浦環、石井和男、"ニューラルネットによる潜水艇の運動の同定"、日本造船学会論文集、Vol.174、pp. 887-892、1993
- [84] 浦環、石井和男、"ニューラルネットを用いた海中ロボットの運動制御におけるコントローラの調整法"、第14回適応制御シンポジウム資料、pp.77-82、1994




- [85] D.R. Yoerger, J.G. Cooke, J.E. Slotine, "The Influence of Thruster Dynamics on Underwater Vehicle Behavior and Their Incorporation Into Control System Design", IEEE Journal of Oceanic Eng., vol. 15, no. 3, 1990
- [86] A.J. Healey et al., "Toward an Improved Understanding of Thruster dynamics for Underwater Vehicles", IEEE Journal of Oceanic Eng., vol. 20, no. 4, 1995
- [87] The Transputer Databook, 2nd ed. INMOS Limited, 1989
- [88] 相良節夫、秋月影雄他、"システム同定"、計測自動制御学会編、1981
- [89] 須田信英、中溝高好、"システム同定の理論と技術"、コンピュータール、vol. 24、コロナ社、1988
- [90] 片山徹、"システム同定の最近の展開"、計測と制御、vol. 31, no. 1、85-90、1992
- [91] 酒井英昭、"システムモデリングの現状と展望"、計測と制御、vol. 31, no. 1、129-132、1992
- [92] 足立修一、"ユーザのためのシステム同定理論"、(社)計測自動制御学会、1993
- [93] 松岡清利、"ニューロコンピューティング"、朝倉書店、1992
- [94] 浦環、石井和男、"ニューラルネットワークによる潜水艇の運動の同定"、日本造船学会論文集、vol. 174、pp. 887-892、1993
- [95] 石井和男、浦環、藤井輝夫、"ニューラルネットワークによる潜水艇の運動の同定(その2:学習過程の改良とコントローラ調整への適用)"、日本造船学会論文集、vol. 177、pp. 429-435、1995
- [96] K. Ishii, T. Ura, T. Fujii, "A Feed Forward Neural Network for Identification and Adaptive Control", Proc. of IJCNN'94, pp. 3216-3221, 1994
- [97] 石井和男、"ニューラルネットによるシステム同定とその学習領域の拡大に関する研究"、東京大学修士論文、1993
- [98] T. Ura et al., "R1 Project - Development of an Autonomous Vehicle Equipped Closed Cycle Diesel Engine for One-Day Investigation of Mid-Ocean Ridge", Proc. of Oceanology International, pp. 1-9, 1992
- [99] 例えば、中村仁彦、"非ホロノミックシステム 第1回非ホロノミックなロボットって何?"、日本ロボット学会誌、vol. 11, no. 4、pp. 521-528、1993
- [100] J.J. Slotine, W. Li, "Applied Nonlinear Control", Prentice Hall, 1991
- [101] 松葉育雄、"バックプロパゲーションによる特徴抽出"、ニューラルネットの数理、pp. 31-37、サイエンス社、1991
- [102] D.R. Yoerger, J.J. Slotine, "Robust Trajectory Control of Underwater Vehicles", IEEE Journal of Oceanic Eng., vol. OE-10, no. 4, pp. 462-470
- [103] K. Ishii, T. Fujii, T. Ura, "A Quick Adaptation Method in a Neural Network Based Control System for Autonomous Underwater Vehicles", Proc. of AUV'94, pp. 269-274, 1994

- [104] K. Ishii, T. Fujii, T. Ura, " An On-line Adaptation Method in a Neural Network Based Control System for AUV's", IEEE Journal of Oceanic Eng., vol. 20, no. 3, pp. 221-227, 1995
- [105] 藤井輝夫、浦環、須藤拓、石井和男、" 自己訓練と学習に基づく海中ロボットの運動制御", ロボット学会誌, vol. 13, no. 7, pp. 112-125, 1995
- [106] 例えば、中野道雄、西山清、" パソコンで解くカルマンフィルタ", 丸善株式会社、1994
- [107] 富塚義、" 適応制御の現状と将来", 計測と制御, vol. 31, no. 1, pp. 122-124, 1992
- [108] 新誠一、" 適応制御とその周辺", 計測と制御, vol. 32, no. 12, pp. 975-980, 1993
- [109] 新誠一、" 適応制御と神経回路網", 計測と制御, vol. 35, no. 6, pp. 437-441, 1996









# Kodak Color Control Patches

© Kodak, 2007 TM Kodak

Blue Cyan Green Yellow Red Magenta White 3/Color Black



## Kodak Gray Scale



© Kodak, 2007 TM Kodak

A 1 2 3 4 5 6 M 8 9 10 11 12 13 14 15 B 17 18 19

