

総合論文

自己訓練と学習に基づく海中ロボットの運動制御

藤井輝夫^{*1}, 浦環^{*2}, 須藤拓^{*3}, 石井和男^{*3}A Neural Network Based Self-learning Control System
for Underwater RobotsTeruo Fujii^{*1}, Tamaki Ura^{*2}, Taku Sutoh^{*3} and Kazuo Ishii^{*3}

This paper describes a neural network based self-learning control system developed especially for autonomous underwater robots. Artificial neural networks can be effective tools for handling difficulties such as nonlinear dynamics and unpredictable disturbances which are often involved in the control problems of underwater robots. Inspired by growing-up processes of biological creatures, a self-learning architecture of neural net controllers has been established by the authors. The principles of the architecture called "SONCS: Self-Organizing Neural-net-Controller System" is presented and the system's feasibility is examined through several real-world applications which include constant depth and altitude swimming of a cruising type autonomous underwater robot "PTEROA", and vibration control of a multi-degree of freedom structure with a damping controllable dynamic damper. It is shown that the neural net controllers can be appropriately adjusted by the proposed self-learning procedures and that the SONCS can be applied to a wide variety of control problems with just easy modifications. New ideas and future perspectives, which include a newly developed quick adaptation methods called "Imaginary Training", are discussed to make the SONCS system more attractive solution for control engineering of actual robotic systems.

Key Words: Neural Networks, Self-organization, Self-learning, Underwater Robots

1. はじめに

海洋や宇宙など人間が直接立ち入ることの困難な環境はロボットに代表される無人機械の活躍が期待されるフィールドである。近年の地球環境に対する意識の高まりに伴って、全地球規模の気候変動を知ろうとする GOOS (Global Ocean Observation System) 計画 [1] あるいはプレート運動に深く関わる中央海嶺付近の調査を目的とした Inter Ridge 計画などが推進されており [2]、これらの中で海洋における新たな直接的観測手段の一つとして海中ロボットが注目を集めつつある。

海中ロボットには様々な形態が存在するが [3]、索を持たない無索無人潜水機においては超音波のみに頼らざるを得ない通信手段を考えると海上から遠隔操縦を行うことは非常に困難であるため、高い自律性を持たせることにより目的の行動を独自に遂行する能力が求められる。従って海洋計測手段の一形態と

して海中ロボットの可能性を拡大していくためには、オペレータの介入なしに海中という未知環境においてロボットが自律的に運動しうるような運動制御手法を確立することが重要課題となる。

海中ロボットの運動は海水という流体中における 6 自由度の運動となるために、一般に非線形性が強い上に運動モード間の相互影響が大きく、事前に正確な運動モデルを構築するためには形状模型を用いた実験が必要となるなど多大な労力と時間を要することが知られている [4][5]。またロボットの開発過程における設計変更や実用時のペイロードの頻繁な交換などに伴い、重量バランスや形状が変更されることによる運動特性の変化についても考慮する必要がある。

一方、近年注目を集めているニューラルネットワークは、その非線形演算能力、並列分散的構造および学習適応能力などの性質を有するために、情報処理ツールとして広い範囲に適用可能で、ロボットの制御をはじめとしてパターン認識や最適化問題など多くの分野において適用例が報告されている [6] ~[12]。例えば予め望ましい入出力関係が分かっているときには、バックプロパゲーション [8] ネットワークを用いて教師付き学習を行うことにより比較的手軽に多入力多出力システムのコントローラを構築することができる [13][14]。学習によって

原稿受付 1994 年 8 月 22 日

*1 理化学研究所化学工学研究室

*2 東京大学生産技術研究所

*3 東京大学大学院工学系研究科

*The Institute of Physical and Chemical Research (RIKEN)

*2 Institute of Industrial Science, University of Tokyo

*3 Division of Engineering, Postgraduate School, University of Tokyo

得られるマッピングの正確さや学習の収束性あるいはコントローラとして用いたときの閉ループ系の安定性など理論的に検討すべき問題は数多く残されているが、このような手軽さと適用範囲の広さは大きな魅力であり、適応的な処理を必要とするシステムの設計者にとってニューラルネットワークは有力な選択肢の一つになっていると言つてよい。

筆者らは以上のような議論をふまえ、海中ロボットの複雑な運動特性やその頻繁な変更、そして海中環境下での潮流をはじめとする未知の外乱などに柔軟に対処しうる制御手法として、ニューラルネットワークによる学習と自己訓練に基づく適応的な運動制御手法である“自己生成型ニューラルネットコントローラシステム”(Self-Organizing Neural Net Controller System: 以下略してSONCSと呼ぶ)を提案し、これを具体的な制御問題に適用することを通してその有効性の検討および改良を進めてきた[15]～[31]。本論文は、これら一連の研究成果について一貫した視点のもとにとりまとめるとともに、ニューラルネットワークを用いたロボットの適応的制御手法に関する将来的展望を明らかにしようとするものである。論文の構成は、まずバックプロパゲーションネットワークを基本構成要素に用い、自己訓練に基づいてコントローラを生成するシステムの一般的構造を示すとともに、自己の運動モデルを表現するためのネットワークの構造について述べる。また、いくつかの具体的な制御問題に対する適用事例を通して提案したシステムの有効性を示すとともに、より実用的なシステムとするために必要な改良点について述べ、さらに最近の研究成果であるコントローラ調整を高速化するための新たなシステム構造の提案などを交えながら、このような制御手法が今後向かうべき方向性や問題点について考察を加える。

2. 自己生成型ニューラルネット コントローラシステム

前章に述べた海中ロボットの運動制御に関する問題に対処するためには、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ようなシステムが必要である。このようなシステムをニューラルネットワークを用いて構築しようとする試みとして、Jordanのネットワークモデル[9]や川入らのフィードバック誤差学習法[10]およびWidrowのTrack Back Upper[12]など、これまでにいくつかのシステムが提案されているが、本論で取り扱う自己生成型ニューラルネットコントローラシステム(SONCS)は、Fig. 1に示すような海中ロボットの成長過程(コントローラの自己生成過程)をバックプロパゲーションネットワークを用いて実現しようとするものである。図中に示されている魚を海中ロボットとみなせば、以下のような過程を考えることができる。

「初期状態のロボットは本能的に制御器の動作のさせかたは分かれるが運動に関する知識を持たない状態である。従ってとりあえず制御器を動かし水の中でもがいてみる。しばらくもがいてみるとによって、ロボットは制御器の動かし方と結果として生じる自分の運動との関係を次第に把握するようになり、やがて自己の運動モデルを形作ってゆく。さらに学習と自己訓練を進めると制御器を意図的に操作して水平に泳ぐことが可能となり、最終的には例えば深度一定などの指令に応じて泳げるようになる。」

すなわち、制御器の動作のさせかた程度の非常に簡単な知識を出発点として、ロボットが自分で泳ぎながら学習あるいは自己訓練を進めることにより、次第に目的に応じたコントローラを生成してゆくというプロセスが実現可能なシステムを以下のように構築する。

2.1 一般的構造

Fig. 2にSONCSの基本構成を示す。SONCSは以下のようないくつかのサブシステムから構成される。

- 1) コントローラ・ネットワーク：制御対象とフォワードモデルに対して制御入力を与える。
- 2) フォワードモデル・ネットワーク：制御対象の運動特性

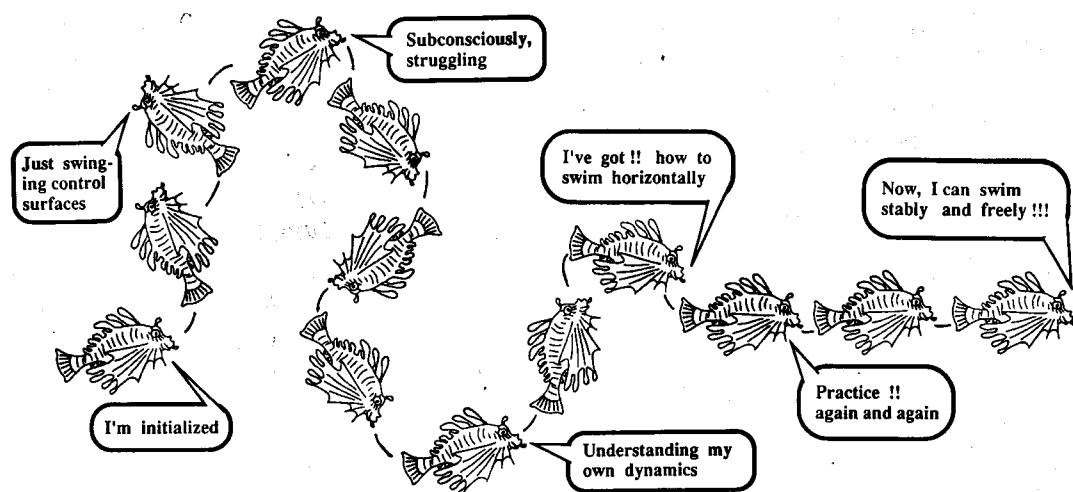


Fig. 1 Growing-up process of underwater robot

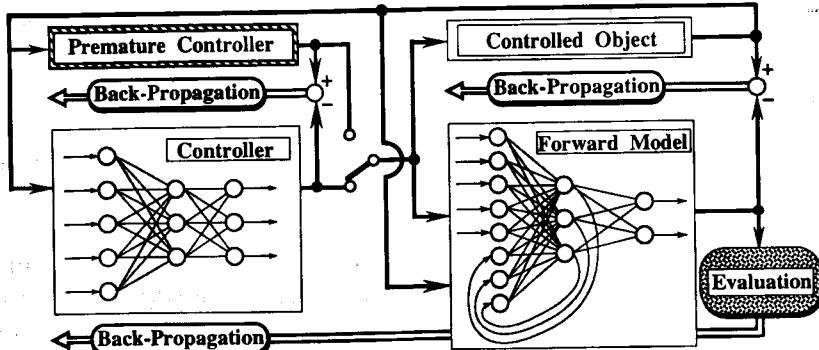


Fig. 2 General structure of self-organizing neural-net-controller system

を表現するモデルで、評価すべき状態量をエミュレートする。

- 3) 評価調整機構：制御結果を評価し、これに応じてコントローラを調整する。
- 4) 未熟なコントローラ：システムを起動する。
システムの基本的な考え方は、特別な教示データを用意することなしにバックプロパゲーション法を用いてコントローラの調整を行おうとするものである。通常のバックプロパゲーション法では望ましい出力と実際の出力との誤差を用いてネットワークの学習が行われるが、本システムにおいてはフォワードモデルの出力を評価すべき制御対象の状態量と同等のものとみなし、これと制御目標との誤差を用いる。Fig. 2 のようにフォワードモデルとコントローラの2つのネットワークを接続し、全体として1つの大きなネットワークとみなせば、この誤差をフォワードモデルを通じて逆伝播されることにより、コントローラの調整を行うことが可能となる。

2.2 フォワードモデル

制御結果の評価に基づいて逆伝播すべき誤差信号を得ることにより、適応的にコントローラを調整するためには、制御対象の運動を把握し、その入出力を参照する機構を持たねばならない。制御対象のフォワードダイナミクスを表現するネットワークは“フォワードモデルネットワーク[9]”と呼ばれる。一般にパターン認識等に用いられる出力側の層への結合を持つニューラルネットワークの場合、ネットワークの入出力信号の間には静的な対応関係のみが成立しており、信号パターンの出現順序は本質的な意味を持たない。これに対して、運動のように信号の時系列的な変化状況が本質的な意味を持つ問題を取り扱うためには、ネットワーク内に何らかの形で過去の入力信号の履歴が現在に影響を及ぼすような回帰的構造が必要である。このようなネットワークによる動的システムの表現については、これまでにいくつか一般的な構造が提案されているが、これについては次章において詳しく取り扱う。

2.3 コントローラの調整

ニューラルネットワークをコントローラとして用いるためには、学習によって制御対象の状態量を適当な条件のもとで目標値に到達させるような性質を習得させる必要がある。予め手本となる制御パターンが得られている場合には、これを教示データとして学習させることにより、ニューラルネットワークの有する飽和特性などの性質により、多入力多出力の系に関しても

ノイズに対してロバストなコントローラが比較的手軽に得られることが確認されている[13][14]。これに対してSONCSでは特別な教示データを用意せずに、制御結果を直接評価することにより、コントローラを調整することを考える。

制御対象の運動に関して評価関数 E^* を定義し、 E^* がより小さいときによりよい制御が行われたとする。コントローラの各結合荷重 w_{ij} を最急降下法によって調整すれば、

$$\Delta w_{ij} = -\epsilon \frac{\partial E^*}{\partial w_{ij}} \quad (1)$$

ここで ϵ は調整速度を決める比例係数である。評価関数は制御の目的に応じて様々な形に設定することができるが、例えば

$$E^* = \frac{1}{2} \int^t (S - S_t)^T A (S - S_t) dt \quad (2)$$

と設定すれば、コントローラは制御対象の状態量 S を目標値 S_t に一致させる性質を持つように調整される。

Fig. 2 のようにコントローラとフォワードモデルを直接連結したネットワークを考えると、式(2)の状態量 S をフォワードモデルの出力でおきかえ、 S_t を教示データとみなせば、 E^* はバックプロパゲーションのための評価関数を時間積分したものと同等なものとなる。従ってフォワードモデルが充分正確に制御対象の運動を表現しているならば、フォワードモデルの出力と制御の目標値 S_t から計算される誤差信号を逆伝播されることにより、コントローラネットワーク部分の結合荷重を制御の目的に応じて調整することができる。すなわち式(2)の評価関数はコントローラネットワークにより発生する誤差を評価しているものと考え、フォワードモデル内では結合荷重の変更は行わず誤差の伝播のみを行えば、コントローラネットワークのみを調整することが可能である。なおフォワードモデルの精度向上は制御対象の入出力データから得られる別の評価関数に基づいてなされるものとする。

2.4 コントローラの生成プロセス

以上のようなコントローラ調整を行なうにあたり、本章の冒頭に述べたように簡単な知識のみに基づいて、コントローラネットワークの初期状態とフォワードモデルを作るための起動作業が必要となる。この間、実用上は制御対象の状態をある程度安定な領域にとどめながら、かつフォワードモデルを得るために運動を励起するようなコントローラが必要となる。すなわち、
1) 正確にチューンされている必要はないが、2) 制御対象の運動に関する定量的な知識なしで簡単に作れるようなコントローラ

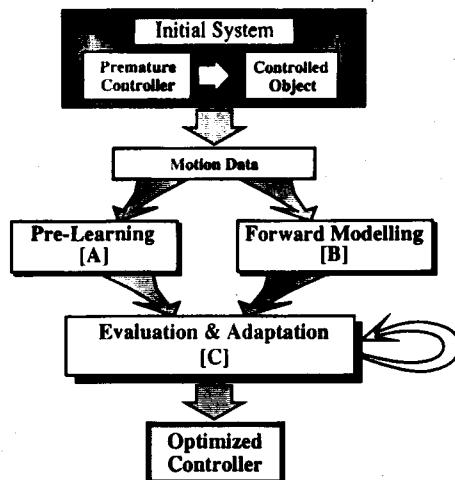


Fig. 3 Organizing process of controller

ーラを用意しなければならない。このようなSONCSを起動するためのコントローラを未熟なコントローラ(Premature Controller)と呼ぶ。

未熟なコントローラによる起動部分を含めたSONCSにおけるコントローラの自己生成過程をFig. 3に示す。図中に示した作業の内容は以下の通りである。

- [A] コントローラの予備学習：未熟なコントローラによる運動データからその操縦を学習することにより、コントローラネットワークの初期値を得る。
- [B] フォワードモデリング：未熟なコントローラによる運動データを学習することにより、制御対象のフォワードモデルを作る。
- [C] 評価・調整過程：制御結果の評価に応じてコントローラを適応的に調整すると同時に、必要があれば制御対象の新たな入出力データに基づきフォワードモデルの変更を行う。

以上のプロセスを考えることにより、ひとたびコントローラネットワークが得られた後も未熟なコントローラをバックアップとして用いることにより、制御対象の状態を重大な事故を招かない程度に安全な領域内に保ちながら、環境条件あるいは制御目的の変化に応じてフォワードモデルの更新やコントローラの再調整をオンラインで行うことが可能である。

3. フォワードモデルの導入

動的システムを取り扱うことが可能な回帰的ネットワーク構造は、これまでにいくつかの一般的な構造が提案されており[32]、SONCSにおいても問題に応じてそれらの構造を採用し、表現される運動の精度の向上や学習に要する時間の短縮などを試みてきた。以下では、それらの中の代表的な構造を取り上げ、それぞれの特徴と具体的な問題に適用する際に留意すべき点を明らかにする。

3.1 入力系列加算型ネットワーク

入力系列の過去の履歴を現在に反映させる最も簡単な構造として、Fig. 4のような入力層のニューロンに回帰的結合を持つものが考えられる[9]。入力層の入出力関数は恒等関数である

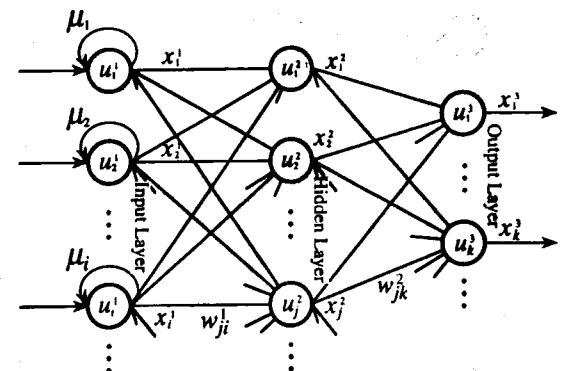


Fig. 4 Forward model network with summed inputs

から、この結合により過去の入力が現在の入力に次式のように影響する。すなわち入力層*i*番目のニューロンに関して、

$$x_i^j(t) = \mu_i x_i^j(t - \Delta t) + x_i^0(t) \quad (3)$$

ここで $x_i^0(t)$ は時間 t における入力層ニューロンへの入力、 $x_i^j(t)$ は時間 t における入力層ニューロンの出力、 μ_i は回帰的な結合の荷重である。これより、 μ_i が 1 より小さいときは、古い入力ほど影響が小さく、新しい入力ほど影響が大きくなる。以下では、このような構造のネットワークを入力系列加算型ネットワークと呼ぶ。この構造では μ_i を入力の持つ性質に応じて調整する手段がなく、予め 1 より小さい適当な値に設定しなければならない点に問題がある。例えば μ_i を全て等しい一定値すなわち $\mu_i = \mu$ として用いた場合、入力信号の周波数構成の変化やチャンネルごとの相違に関わらず、過去の入力が現在の値に対して一定の影響を及ぼすことになる。従って、実用時に学習時と周波数構成の著しく異なる入力が起こる場合や入力のチャンネルごとに信号の特性が異なる場合にはフォワードモデルの出力が現実と合わなくなる可能性がある。

3.2 エルマンネットワーク

一般にエルマンモデル[32]と呼ばれるネットワークは、中間層の1時間ステップ前の出力を表すニューロンを入力層に附加することによって、信号の履歴を取り入れる構造となっている(Fig. 5)。この構造では、前節に述べた入力系列加算型のネットワークと異なり、新たに附加したニューロンから中間層への結合荷重を調整することにより、過去の入力の回帰的な影響を学習すべき入出力関係に応じて調整することが可能となっている。新たに附加したニューロンから中間層への結合荷重を他と区別して w_{ij}^p と表せば、入力層から中間層に至る演算は、例えば中間層第1番目のニューロンに関して

$$u_i^p(t) = \sum_j w_{ij}^p x_i^j(t) + \sum_l w_{il}^p x_l^p(t - \Delta t) \quad (4)$$

と表される。 w_{ij}^p に関する学習は、通常の結合荷重と同様に、例えば中間層第1番目のニューロンにいたる結合荷重の修正量 $\Delta w_{ij}^p(t)$ に関して

$$\begin{aligned} \Delta w_{ij}^p(t) &= \eta \delta_i^p x_i^p(t) + \alpha \Delta w_{ij}^p(t - \Delta t) \\ \delta_i^p &= f'(u_i^p(t)) \sum_k \delta_k^p w_{kj}^p \end{aligned} \quad (5)$$

で表される。ここで f はバックプロパゲーションネットワークにおける出力関数として通常用いられるシグモイド関数、 δ は一般化デルタルールによって計算される誤差信号である。

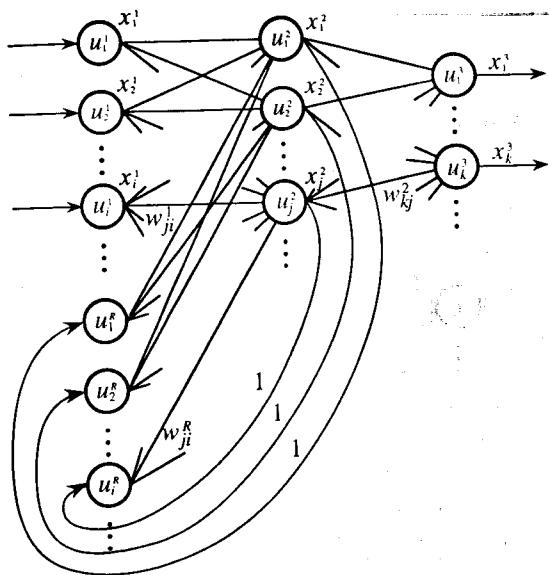


Fig. 5 Elman-type forward model network

[8]。この場合、中間層から入力層にいたる回帰的な結合 (=1) からくる誤差は小さいとして無視する。

入力系列加算型とエルマンモデルの時系列的な情報の表現能力を比較するために具体的な非線形運動方程式で表される系の入出力関係を学習させ、その系の振る舞いをエミュレートさせた結果、特に学習時よりも高い周波数領域での応答に関して、エルマンモデルの方が位相や絶対値における精度および追加学習による適応の能力ともに優れていることを確認している[18]。このことは、SONCS の初期化プロセスにおけるフォワードモデリングの時間短縮と制御対象の運動特性変化への対応能力の向上に寄与するものである。

3.3 差分型ネットワーク

SONCSにおいてコントローラが適切に調整されるためには、制御において評価すべき状態量そのものだけでなく、その制御量に関する偏微分値の振る舞いがフォワードモデルによって正確に表現される必要がある。コントローラの調整はフォワードモデル内を逆伝播する誤差信号によって行われるが、この誤差信号は評価関数をコントローラの出力である制御量で偏微分した値に基づくものである。通常、ネットワークの入出力関係が現実のものと一致すれば、その制御量に関する偏微分値も一致するものと考えられるが、ネットワークの入力数が多い場合や入力同士の相関がある場合には簡単な教師データ列を与えるだけで偏微分値まで合うようなフォワードモデルを作ることは困難であるとの指摘がなされている[23]。このような問題に対処する方策として、Fig. 6 に示すように評価関数に用いる状態量の高次差分を出力し、出力層において差分値を加算することにより状態量を得るようなフォワードモデルネットワークが有効である。ここでは便宜的にフォワードモデルに入力される状態量と制御量を区別して、それぞれ $S(t)$, $u(t)$ と表し、ネットワークによって表現される写像を F と表すと、通常のネットワークでは以下の関係が成立する。

$$S(t+\Delta t) = F(S(t), u(t)) \quad (6)$$

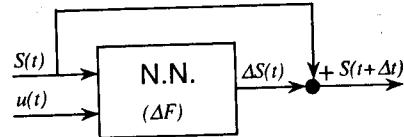


Fig. 6 Structure of difference type network

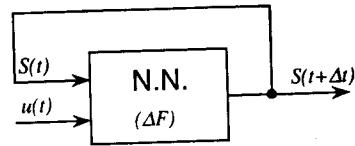


Fig. 7 Structure of auto-regression type network

これを入力とその差分量の和として書き換えると、

$$\begin{aligned} S(t+\Delta t) &= S(t) + \Delta S(t) \\ &= S(t) + \Delta F(S(t), u(t)) \end{aligned} \quad (7)$$

バックプロパゲーション法ではネットワーク出力の絶対値を一致させるように学習がすすめられるために、 ΔS の各成分が S の各成分に比べて小さい場合 $S(t+\Delta t)$ を表現するネットワークを作ることは、ほとんど恒等関数に近い写像を学習することになり非常に困難である。 F を表現するネットワークを作らずに ΔF を表現するネットワークを作り、差分 $\Delta S(t)$ を出力させてから入力（すなわち $S(t)$ ）に加えた方が、フォワードモデルとしての精度が向上すると同時に制御対象の高次の差分値の振る舞いまで正確に表現することが可能となる。このタイプのネットワークを差分型ネットワークと呼ぶ[23]。

3.4 出力回帰型ネットワーク

充分に精度のよく制御対象の入出力関係を表現するフォワードモデルが得られる場合、Fig. 7 に示すように入力として用いる状態量の全てを出力から得る構造を実現することができる。以後この構造を出力回帰型ネットワークと呼ぶ。これまでに挙げてきた 3 つのタイプのネットワークでは、各時間ステップ毎に状態量の計測値を入力として与える必要があるが、この構造においてはその必要はなく、数値積分による運動方程式の解法と同様に、状態量の初期値と制御量の系列を与えることによって、制御対象の応答の系列をエミュレートすることが可能である。従って、この構造を SONCS のフォワードモデルとして用いれば、オンラインであっても状態量の計測周期とは無関係に使用可能な計算機の処理能力に応じてオフライン的にコントローラの調整を行うことができる。

このような回帰的構造には一般に、出力における誤差が増幅されて最終的に発散してしまうなどの不安定な性質が存在するため、学習にあたっては、まず出力回帰を行わない状態である程度精度が得られるまで学習を行い、その後に出力を直接入力する閉じた構造を実現するという段階的な方法をとる必要がある。筆者らは、この出力回帰型ネットワークと前節までに述べたエルマンネットワーク、差分型ネットワークを複合した構造を持つネットワークを用いることを提案しているが、その際にも差分の次数と出力回帰の有無に応じて 4 段階に分けた学習プロセスによってフォワードモデルを構築している[31]。

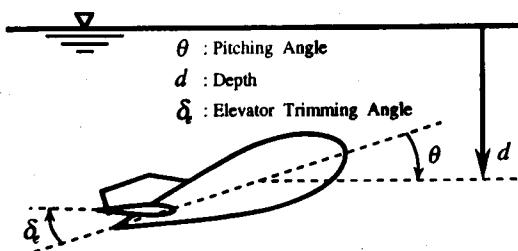


Fig. 8 Longitudinal motion of PTEROA

4. SONCS の適用事例

SONCS は、以上述べてきたように制御対象の運動特性および動作環境を正確に知ることが困難である場合の制御手法として、従来の明示的な運動の数学モデルに基づく手法とは異なる一般的な枠組みを与えるものである。本章では具体的なハードウェアを対象とする制御問題を取り上げ、SONCS が制御手法として広い範囲の問題に適用可能であることを示すとともに具体的な適用例を通してその有効性を検討する。

まずははじめに最も単純な例として、筆者らが開発してきた航行型海中ロボット“PTEROA[3]～[5]”艇の深度保持に SONCS を適用した例を示し、適切にコントローラが生成されることを示す。また、海中ロボットの運動制御以外の問題として、電気粘性流体(ER 流体)を用いた可変減衰型動吸振器による複数自由度構造物の振動制御を考え、SONCS によって減衰を制御することにより、一つの動吸振器によって複数の振動モードを低減することを試みる。この適用例では、SONCS に必要となる全ての処理プロセスをオンラインで行い、実時間でのコントローラの調整を想定する。さらに、航行型海中ロボットの海底面に対する一定高度航行の問題への適用例を示す。海中ロボットが一定高度で航行するためには、超音波などの手段で海底面形状の情報を獲得することが必要となるが、このような環境に関する情報を取り込み、制御情報として用いるためのシステムの拡張について述べる。

4.1 航行型海中ロボットの深度保持制御

SONCS の基本的な機能を裏付けるための比較的単純な例として、筆者らが近年開発を行っている航行型海中ロボット PTEROA の一定深度航行の問題への適用を考える。制御の目的は Fig. 8 に示すように、エレベータの操作によって目標ピッチ角 θ_t を保ちながら目標深度 d_t 一定で航行することである。以下では、PTEROA の運動制御を検討するための小型有索テストベッドである PTEROA 60[14]～[16]を用いた水槽実験を通して、SONCS によるコントローラ生成の過程を示す。

(1) 未熟なコントローラ

SONCS を制御対象に関する簡単な定性的知識のみに基づいて起動するために、ここでは単純なファジィコントローラを未熟なコントローラに用いる[15]。ファジィ制御はいくつかのルール群を基本としており、ニューラルネットワーク等に比べ人間にとて理解しやすいものとなっているため、未熟なコントローラのように制御対象をある程度安定な領域にとどめるという目的のみを考えるときには、精密にチューニングする必要が

if	Δd (cm) is	$\Delta \theta$ (deg) is	then	$\Delta \delta_e$ (deg) is
Rule 1	UP -30 0 30	NEUTRAL -20 0 20	→	DOWN 0 -30 0 30
Rule 2	DOWN 0 30 -30	NEUTRAL -20 0 20	→	UP -30 0 30
Rule 3		UP -10 0 10	→	DOWN 0 -30 0 30
Rule 4		DOWN 0 10 -10	→	UP -30 0 30

Fig. 9 Fuzzy algorithm for premature control

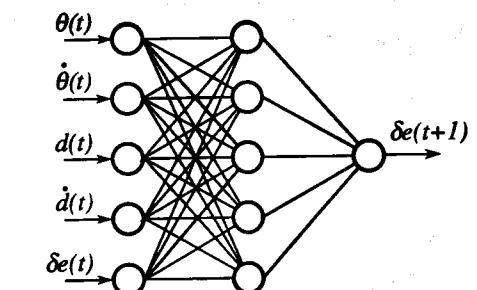


Fig. 10 Structure of the controller network

なく、比較的手軽にコントローラを構成することが可能である。PTEROA 60 の運動に関しては例えば Fig. 9 に示すような、ロボットのピッチ角が頭上げになった場合はエレベータを下げ、頭下げになった場合はエレベータを上げるといった程度の非常に簡単なルール群からなるファジィコントローラを定義し、これによってロボットを実際に運動させることにより、SONCS の起動に必要なネットワークの初期化を行う。Fig. 12 の最上段のグラフが未熟なコントローラによる PTEROA 60 の航行結果で、このプロセスはすなわち第 2 章冒頭に述べたロボットが本能的に制御器を動かして水の中でもがいてみる段階に対応するものである。

(2) ネットワークの初期化

未熟なファジィコントローラによる航行によって得られた Fig. 12 最上段のデータに基づき、SONCS のコントローラネットワークを初期化すると同時にフォワードモデルを構築する。コントローラネットワークには通常のバックプロパゲーションネットワークを用い、Fig. 10 に示すような入出力を考える。また、フォワードモデルには前章に述べた最も単純な構造である入力系列加算型ネットワークを用い、学習時間短縮のために評価に用いるピッチ角 θ および深度 d を出力するネットワークをそれぞれ単独に構築する (Fig. 11 参照)。Fig. 12 の上

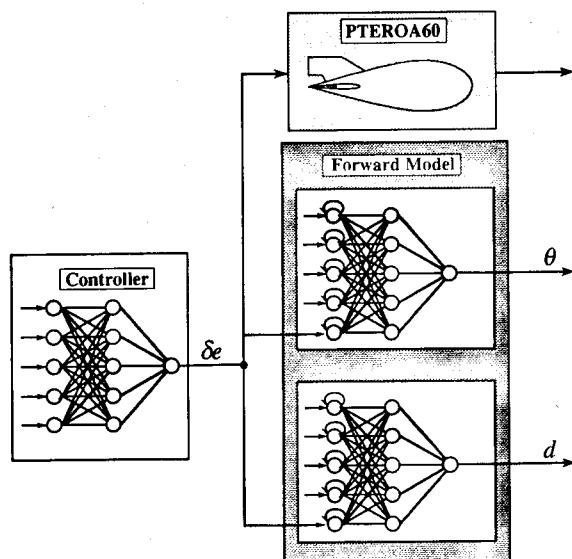


Fig. 11 Network structure for PTEROA 60

から2段目のグラフは未熟なコントローラの制御動作を学習することにより初期化されたコントローラネットワークによる航行結果である、この段階のコントローラネットワークは特に目的を持った制御動作を行っているわけではなく、単に未熟なコントローラを模倣した動作を行っている状態である。

(3) コントローラの適応

海中ロボットのテストベッド PTEROA 60 の一定深度における水平航行を実現するために、以下のような評価関数を導入してコントローラの適応を行う。

$$E^* = \frac{1}{2} \int^t \{a_1(\theta - \theta_t)^2 + a_2(d - d_t)^2\} dt \quad (8)$$

ここで、 a_1 および a_2 はピッチ角 θ と深度 d に関する重み付けを行うための定数である。前節で初期化したコントローラネットワークを出発点として、目標深度 $d_t = 0.5[m]$ 、ピッチ角 $\theta_t = 0.1 [rad]$ の条件で4回の調整を行った。Fig. 12 に各調整後のコントローラによる制御結果を示す。コントローラが次第に

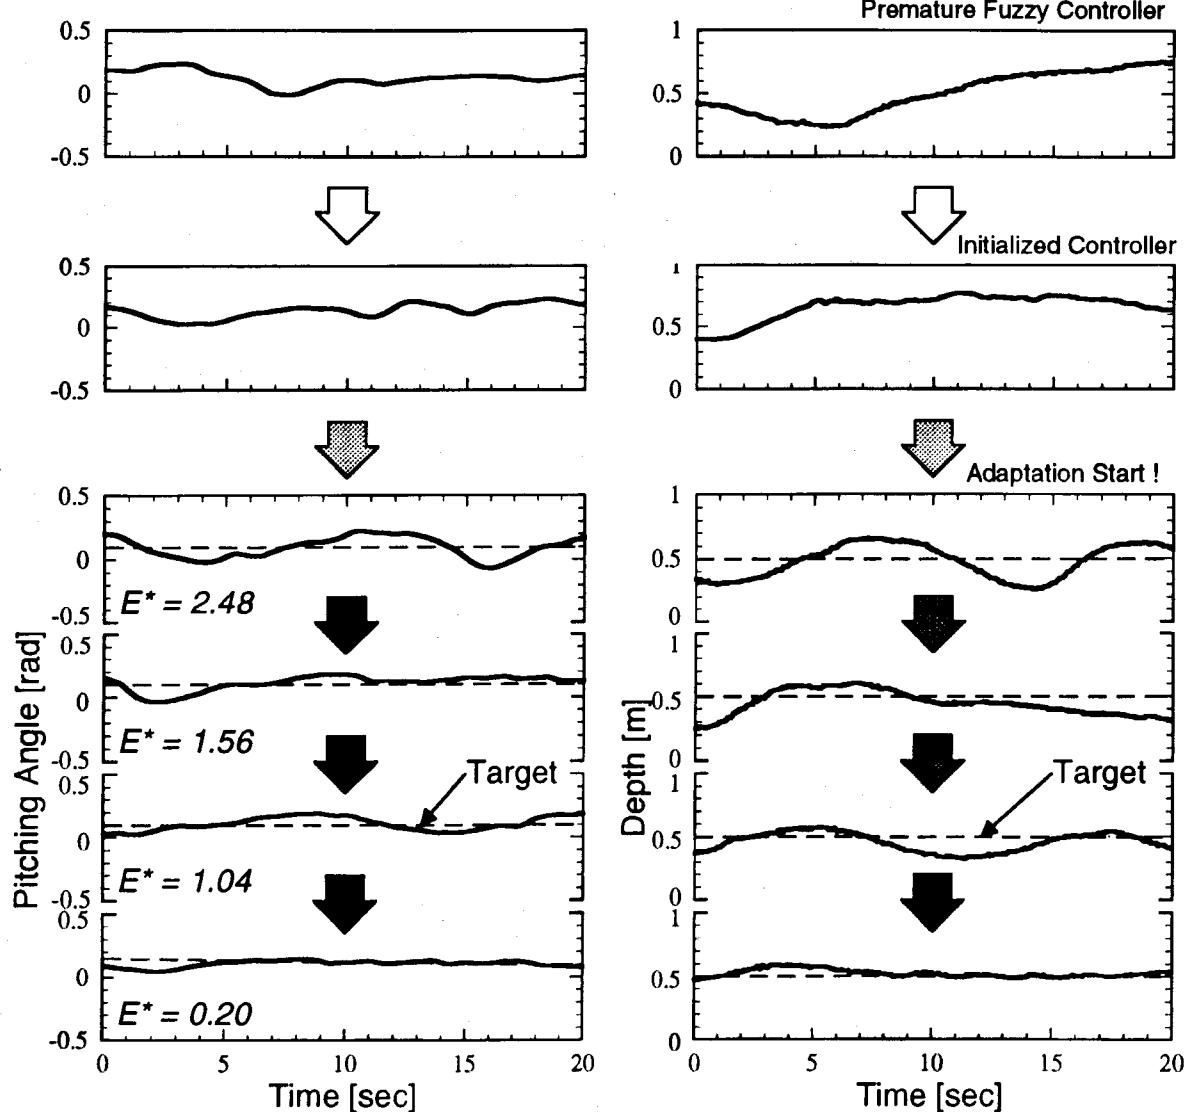


Fig. 12 Experimental results of controller adaptation for PTEROA 60

PTEROA 60 を制御できるようになり、評価値の減少からも明らかのように最終的に目標の状態において安定に航行させる能力が得られている。

4.2 可変減衰型動吸振器の減衰制御

海中ロボット以外の問題として、可変減衰型動吸振器 (Damping Controllable Dynamic Damper: DCDD) による構造物の振動制御に SONCS を適用した例を取り上げる。動吸振器は一般に質量、バネおよび減衰要素からなる制振装置であり、構造物に取り付けることで質量の逆共振作用と減衰器のエネルギー散逸作用で構造物の振動を抑えるものである。ここで取り扱う動吸振器は、その減衰要素に ER (Electro-Rheological) 流体を用い、与える電場の強さに応じて粘性が変化する電気粘性効果により、減衰を可変としたものである。動吸振器は本来、固有振動数に等しい振動しか制振できないが、減衰を動的に変化させることにより、異なる 2 つの周波数の振動を単独の動吸振器によって低減させることができると期待される。このような目的で減衰を制御するコントローラを考える場合、1) 構造物の状態量としては、一般に加速度のみが計測可能であること、2) 構造物、動吸振器および ER 流体からなるシステム全体の動特性は通常非線形であると同時に経時変化を伴うものであることなどを考慮する必要がある。以下では、これらの条件をふまえて SONCS をこの問題に適用し、加速度とその変化率のみをもとに構造物の振動を低減するコントローラを適応的に生成した実験の結果を示す。

Fig. 13 のような一方を励振器に固定し、他方を自由端としたビーム構造を考え、自由端に可変減衰型動吸振器を取り付けて、動吸振器への入力電圧 V を変化させ、減衰を制御することにより構造の振動を抑える。3箇所に取り付けられた加速度計の計測値はコンピュータに取り込まれ、SONCS の初期化からコントローラの生成に至る全てのプロセスはコンピュータ内におけるオンライン計算で実行される。用いた SONCS の構造を Fig. 14 に示す。ここではエルマンネットワークをフォワードモデルに採用し、計測可能な加速度 \ddot{x}_i と制御入力のみを用いて制御対象の状態量を出力するネットワークを実現している。構造の 1 次モードに関しては動吸振器の固有振動数をこれに合わせてセットすることにより、動吸振器そのものの効果として振動を抑えることが可能であるため、2 次のモードに対応するビーム中央部の加速度 \ddot{x}_2 を抑えるように、

$$E^* = \frac{1}{2} \int^t (\ddot{x}_2)^2 dt \quad (9)$$

で表されるような評価関数を定義する。式(9)の評価関数を減少させるように SONCS によって調整されたコントローラに

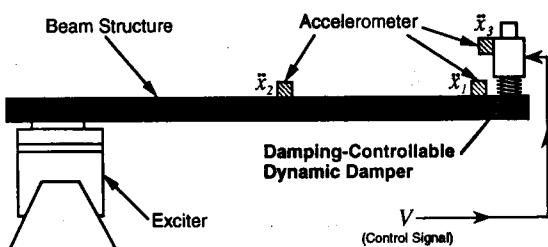


Fig. 13 Experimental set-up of a beam structure

よる制御結果を Fig. 15 に示す。動吸振器なしでは 2 つの卓越した振動モードが存在するが (Fig. 15 上段), 動吸振器を取り付けた段階では 1 次モードのみが抑えられた状態となっており (Fig. 15 中段), さらに SONCS によってコントローラを調整することにより、2 次モードに関しても振動が低減されている (Fig. 15 下段)。

以上の結果より、非線形な動特性を有するデバイスを用いたセミアクティブ制御の問題についても SONCS が適用可能であり、充分な計算能力を有するコンピュータが使用できる場合には、初期化からコントローラの調整までの全ての過程をオンラインで実行可能であることが確認された。

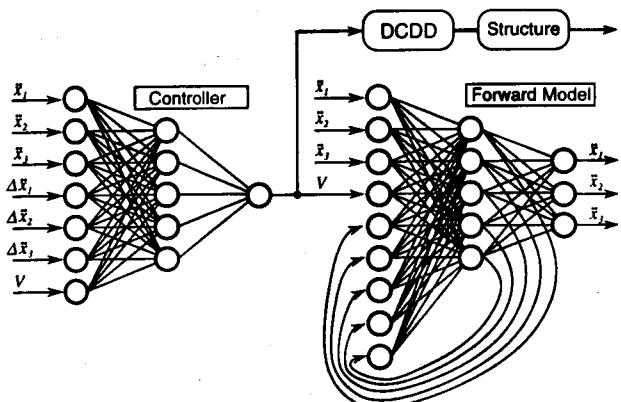


Fig. 14 Network structure for vibration control

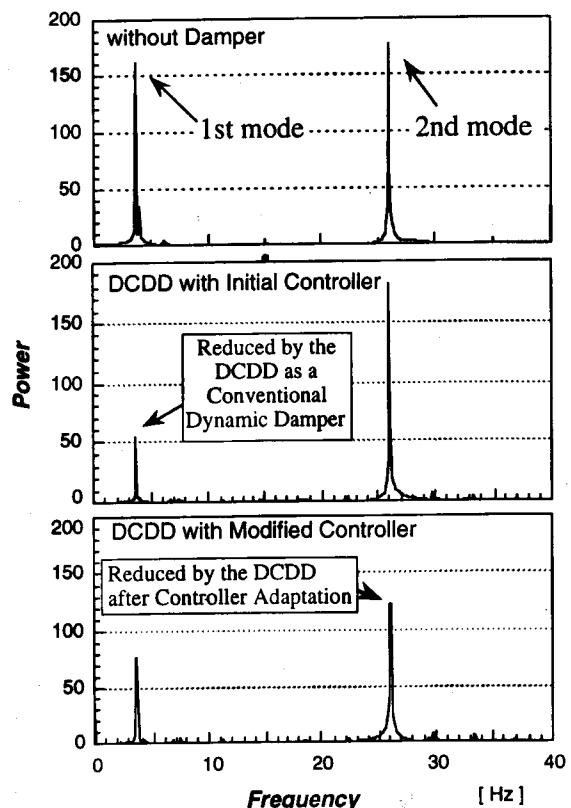


Fig. 15 Experimental results of vibration control

4.3 PTEROA150 の高度保持制御

航行型海中ロボット PTEROA は、Fig. 16 に示すように 4 方向に関して超音波測距センサを搭載している。海底面上の形状が平坦でない場合、一定高度を保ちながら航行するためには、これらのセンサによって得られる距離情報をもとに海底面の形状を推定しながら航行しなければならない。このような問題に SONCS を適用する場合には、超音波センサによって計測される距離データなどに代表される環境に関する情報を制御情報として扱う必要がある。ここでは PTEROA 150 艇[3]～[5]について、連続した三角形断面からなる海底面上での一定高度航行の制御に SONCS を適用した例をシミュレーションによって示す。

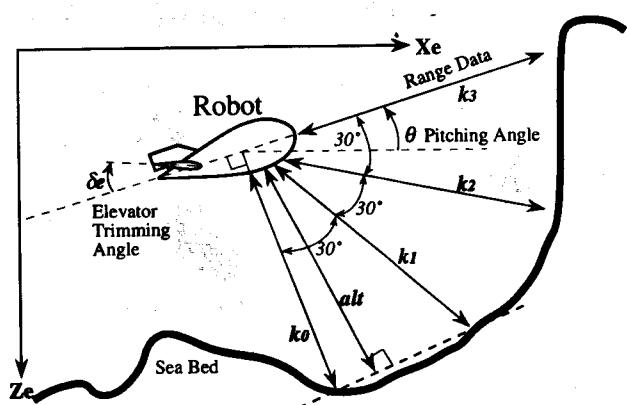


Fig. 16 Configuration of a robot and ultrasonic range finders

Fig. 16 のように測距装置によって測定される距離をそれぞれ k_0, k_1, k_2, k_3 と定め、制御の目的は底辺 50[m]、高さ 10[m] の連続した三角形断面で構成された地形の上を一定高度 $alt = 10$ [m] で航行することとする。ここで高度とはロボットと k_0 および k_1 に対応する超音波ビームが反射する点で定められる直線との距離とする。この問題を SONCS で扱うためには、ロボットの運動と測距データに基づいて高度を出力するようなフォワードモデルを構築する必要があり、特に測距データ k_0, k_1 と高度との写像関係はロボットの運動と無関係に求めることが可能である。従って Fig. 17 に示すように、フォワードモデルを運動を表現する部分 (Dynamics Network)、運動と測距データから次の時間ステップの k_0 および k_1 を計算する部分 (Geometric Network) と高度を算出する部分 (Altitude Network) とにモジュール化した構造を採用し、より高い精度のフォワードモデルを少ない学習時間で実現することが可能となっている。図中の Dynamics Network および Geometric Network には差分型ネットワークを用いており、塗りつぶしの黒丸はネットワークの出力である差分値に 1 時間ステップ前の値 (ネットワークの入力) を加えていることを示している。Fig. 18 に初期状態のコントローラおよび調整を 11 回行った後のコントローラの制御結果の比較を示す。高度に関する誤差が約 1/4 に減少していることからも明らかなように、目的のコントローラが得られている。

以上の結果から、SONCS の全体構造に若干の工夫を考えることにより、制御対象の状態量以外に距離センサのデータなどの環境条件に起因する情報についても制御情報として扱うこと

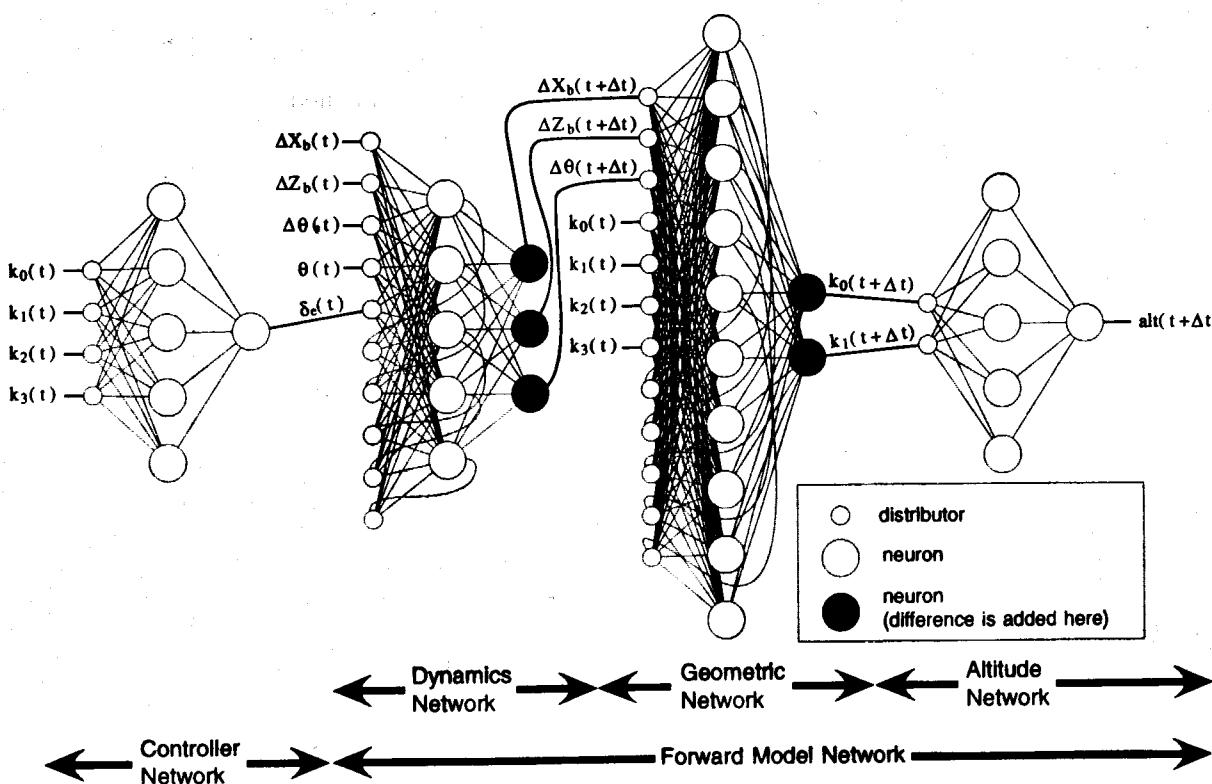


Fig. 17 Network structure for constant altitude swimming

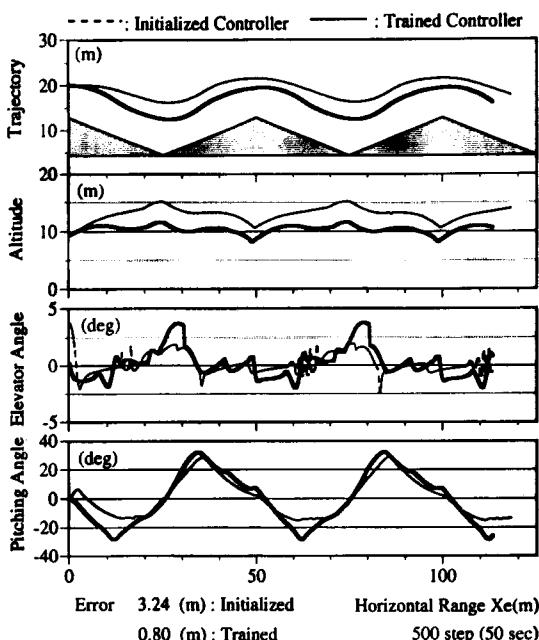


Fig. 18 Comparison between the initialized controller and the trained controller

が可能であることが示された。このことは、複雑な制御問題にも柔軟に対処しうる制御システムとして、SONCS の広い範囲の問題への応用可能性を示唆するものである。

5. 新たな展開と将来展望

以上述べてきたように、SONCS は広い範囲の問題に適用可能な制御方式であり、複雑な問題に対しても柔軟な動作が期待できる適応的制御システムである。しかしながら、例えばコントローラ調整の際には対象とするシステムを何度も動作させて、訓練と学習を行う必要があることなど、実用上の問題点がいくつか存在する。本章では、それらの問題に対処するための工夫について述べるとともに、ニューラルネットワークを用いた訓練と学習に基づく制御方式の今後の展開について考察する。

5.1 暫定教示データによるコントローラの初期調整

SONCS におけるコントローラの調整は、ある動作期間を定め、その間の評価値に基づく誤差信号を逆伝播することにより行われる。従ってある動作結果に対応する誤差信号は動作後に計算され、これによって1回しかコントローラの調整を行うことができない。このような方法でコントローラの調整を繰り返すことは教師あり学習において毎回違う教示データを用いて学習を進めることに相当し、学習が進みづらく、コントローラの調整に多くの時間を要することは容易に理解される。このような状況を避けて訓練回数を減らし、より適切にコントローラの調整を行う手段の一つとして、例えば第4章3節の海中ロボットの高度保持制御の例では暫定教示データ学習法[23]を導入している。

u_i を訓練中の時間ステップ i でのコントローラネットワークの出力とすると、時間ステップ i における暫定教示データ

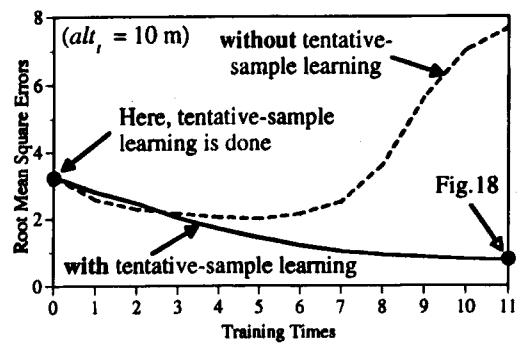


Fig. 19 Comparison of errors in altitude

\hat{u}_i は以下のように定義される。

$$\hat{u}_i = u_i + \Delta u_i \quad (10)$$

ここで Δu_i は次式によって与えられる。

$$\Delta u_i = -\xi \frac{\partial E^*}{\partial u_i} \quad (11)$$

ここで ξ はバックプロパゲーション法で用いられる学習定数に相当する正の定数である。式(11)右辺の偏微分値はバックプロパゲーションの計算を行う際にフォワードモデルネットワーク内部で生成される値であるため、これを直接利用することができる。偏微分の意味により、 u_i を Δu_i の方向に少し動かせば E^* の値は減少することになる。このことは、 \hat{u}_i がコントローラ調整のための暫定的な教示データとして採用できることを意味しており、例えばコントローラ調整の初期に、これを用いた教師付き学習を繰り返すことにより、以後の訓練を速やかに進めることができる。

第4章3節の問題に対して、コントローラ調整の初期に暫定教示データ学習を行った場合とそうでない場合の学習の進み具合の比較を Fig. 19 に示す。暫定教示データ学習を行った場合には、Fig. 18 にも示したように11回の訓練によって、二乗誤差が約1/4のコントローラが得られているが、行わない場合については、訓練を進めるにつれて二乗誤差が増大し、さらに訓練を要する結果となっている。実際、この問題について暫定教示データ学習を行わない場合、文献[22]においては有用なコントローラが得られるまでに、54回の訓練が必要となっている。以上のように暫定教示データ学習をコントローラの初期調整に用いることにより、ある特定の動作パターンに関してのみではあるが、コントローラが持つべき基本的な傾向を効率よく獲得させることができあり、そのような基本的傾向を予め備えておくことにより、その後の訓練回数をも減らすことができる。

5.2 高速学習のための2重構造化

SONCS においてコントローラ調整に時間が必要とする原因として、前節に述べた学習の収束過程に起因するもの以外に、制御対象を実際に何度も動作させて訓練を行わなければならないという訓練プロセスそのものが時間を要するものとなっている点に留意する必要がある。これは、主としてこれまでに示した適用例において用いてきたフォワードモデルネットワークの構造が、1時間ステップ前の制御対象の状態量を入力として、次のステップの状態量を出力するものとなっているためである。す

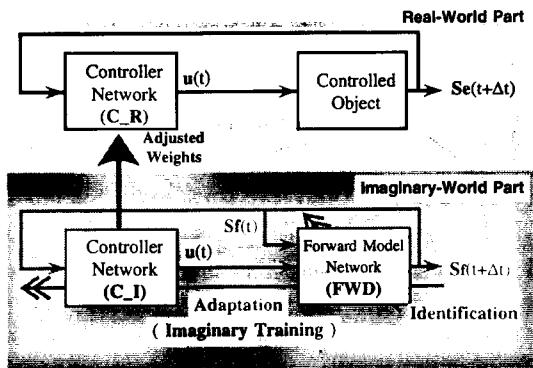


Fig. 20 Structure for imaginary training

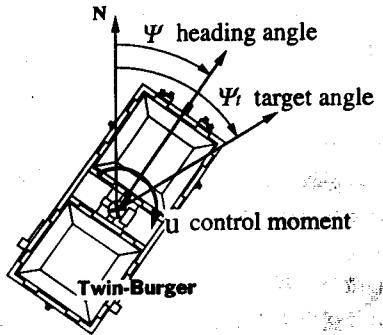


Fig. 21 Heading control of the twin-burger

なわち、フォワードモデルは制御対象の運動特性を表現するモデルであるにもかかわらず、第3章1節から3節までに述べた構造を採用している限りにおいては、コントローラによる制御結果を評価するために、制御対象から直接得られる状態量の系列が必要となってしまう。これに対して第3章4節に述べた出力回帰型のネットワークを用いれば、状態量の初期状態と制御入力の系列を与えることにより、制御対象を実際に動作させることなく応答の系列を得ることが可能となる。この形式のネットワークをSONCSのフォワードモデルとして導入すれば、Fig. 20に示すような制御対象を仮想的に動作させてコントローラの学習を効率的に行う構造が実現できる。

Fig. 20中のReal World Partは実際に制御対象を制御する部分であり、コントローラネットワークと制御対象からなるフィードバック制御系が構成されている。また、Imaginary World Partはフォワードモデルで表現された仮想的な制御対象を動作させる部分である。SONCSをこのような構造とすることにより、Real World Partにおける実世界でのオペレーションと無関係にImaginary World Partにおいてコントローラの訓練を行い、これを調整することが可能となる。必要に応じてReal World Partのコントローラネットワークの結合荷重をImaginary World Partのものに書き換えることにより、充分な調整を済ませたコントローラを実作業に用いることができる。これら一連のコントローラ調整過程を以後“仮想訓練(Imaginary Training)”と呼ぶ。対象とするロボットが並列処理機能を有するコンピュータシステムを搭載している場合には、この仮想訓練をオンラインで行うことができ、動作条件の

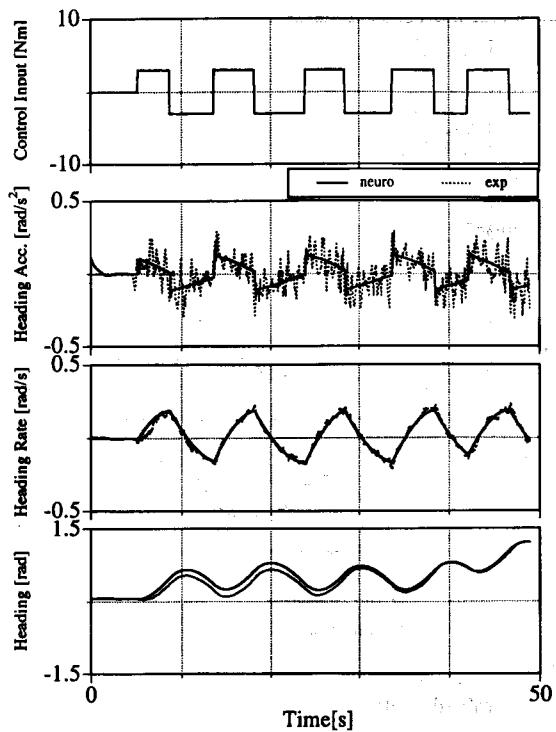


Fig. 22 Limit cycle motion of the twin-burger

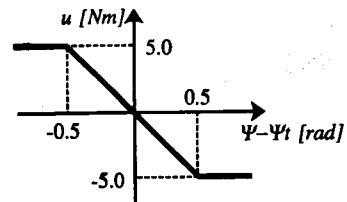


Fig. 23 I/O function for controller initialization

変化などに対して、より一層迅速に対処することが期待される。

仮想訓練の手法の適用例の一つとして、筆者等が開発を進めている海中ロボット“Twin-Burger[33][34]”の方位保持制御を行った例を示す。Twin-Burgerはトランシスパレータを基本要素としたマルチプロセッサシステムを搭載しているので、2重構造化したSONCSをうまくインプリメントすることにより、環境条件の変化に応じてオンラインで仮想訓練を行うことにより柔軟な運動制御システムを実現可能である。ここではその前段階としてFig. 21に示すようにロボットの方位 ψ を目標値 $\psi_t = 0 \text{ [rad]}$ に保持するコントローラを仮想訓練によって生成することを考える。仮想訓練に先立つSONCSの初期化プロセスとして、Fig. 22に示すようなTwin-Burgerの方位に関するリミットサイクル運動のデータをもとにフォワードモデルを構築する。図中の実線が構築したフォワードモデルの出力、点線が実験データをそれぞれ表しており、ノイズを含むデータであるにもかかわらず良好な運動のモデルが得られていることがわかる。また、Fig. 23に示すような簡単な入出力関係を有するコントローラを未熟なコントローラとして用い、その制御動作を学習することによってコントローラネットワークの

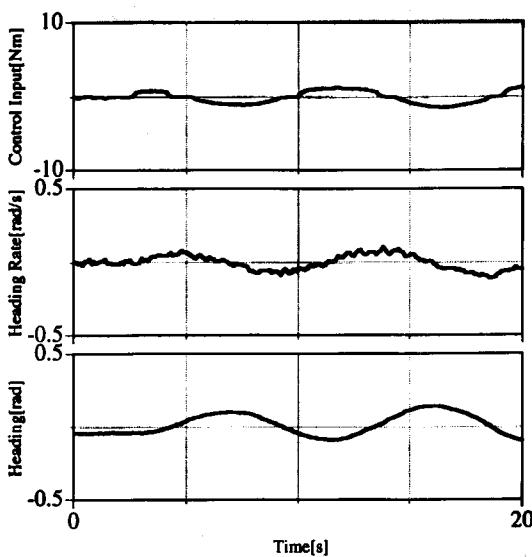


Fig. 24 Experimental results controlled by initialized controller

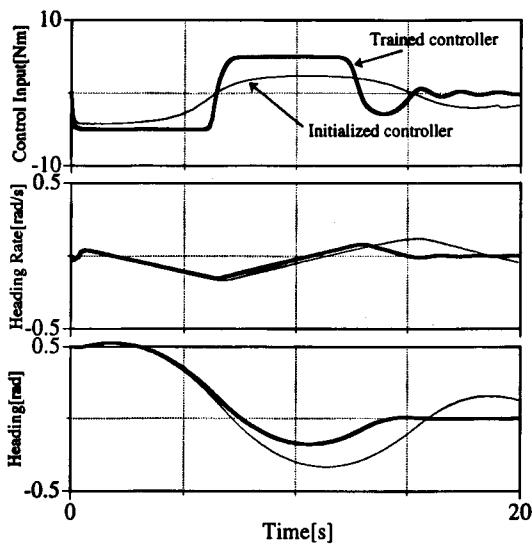
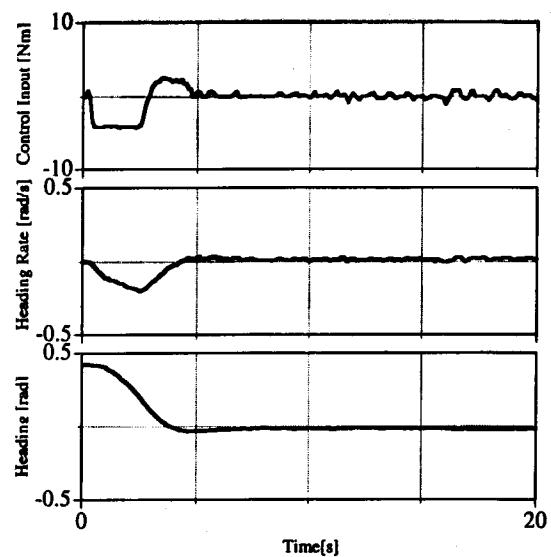
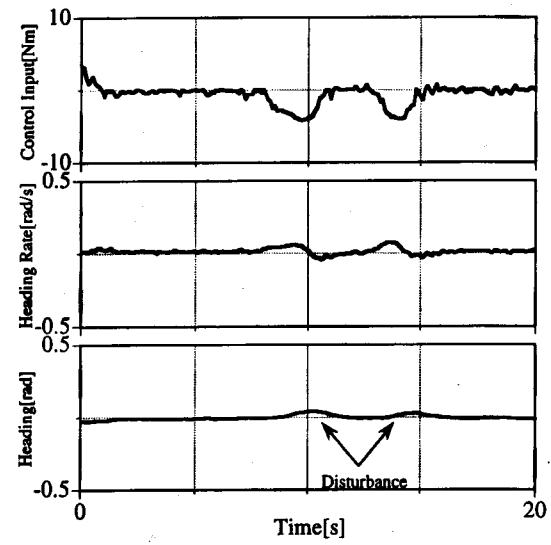


Fig. 25 Result of imaginary training

初期化を行った。初期化されたコントローラによって Twin-Burger の制御を行ったところ、Fig. 24 に示すように初期状態の微小な誤差に対して振動が生じる結果となった。この初期化されたコントローラを SONCS の Imaginary World Part において仮想訓練を行った結果を Fig. 25 に示す。図中のデータはフォワードモデルの出力であり、細線が初期化されたコントローラによる制御結果、太線が仮想訓練による調整後のコントローラによる制御結果を表す。なお、調整の効果を見やすくするために、ここでは方位の初期値を 0.5[rad]としている。初期化されたコントローラによる制御では、実験結果と同様振動が持続しているが、調整後のコントローラは多少のオーバーシュートが見られるものの、方位を目標値に保持する特性が実現されている。Fig. 26 および Fig. 27 に調整後のコントローラによって Twin-Burger の方位制御を行った結果を示す。Fig. 26 では方位の初期値として約 0.4[rad]を与え、Fig. 27 では約 8

Fig. 26 Experimental results controlled by trained controller
(Initial heading angle is approximately 0.4 [rad])Fig. 27 Experimental results controlled by trained controller
(Disturbances are applied at 8 [sec] and 13 [sec])

秒および 13 秒の時点において外乱を与えていたが、いずれも方位を目標値に保つ制御が実現されている。以上の結果から、SONCS において仮想訓練を行うことにより、実際に制御対象を動作させることなく目的のコントローラが得られることが確認された。今後は、2 重構造化した SONCS のソフトウェアを Twin-Burger のトランスペュータ上にインプリメントし、環境条件の変化に対するコントローラのオンライン調整の実現を予定している。

5.3 今後の展望

前節までに SONCS を訓練と学習に基づく制御システムとしてより実用的なものとするための技術的展開について述べた。SONCS のみならずニューラルネットワークを用いた制御システム全体に関して、今後より一層実用的で広い応用範囲を実現していくためには、以下に挙げるような問題について積極

的に検討を行うことが重要である。

5.3.1 知識の蓄積

ニューラルネットワークの学習を行う際に、ひとたび学習を進めてしまうと、以前にネットワークが獲得していた知識が序々に失われてしまうという問題がある。従って、以前に経験した問題に関する知識を有効に利用することができず、環境条件が変化するたびに学習によってそれに適応しなければならない。これに対して、経験した環境条件のそれぞれに対応するネットワークを蓄積し、環境条件に応じて使用するネットワークを取り替えるという方法をとれば、以前に経験した条件に対して再度適応する必要が生じない。これを実現する方法として、筆者らは学習した入力領域を記憶する随伴ネットと名付けたネットワークを導入することにより、遭遇した環境条件がそれまでに経験したものであるかを見分け、その判別結果に応じて使用するネットワークを切り替える方法を提案している[28]。

5.3.2 コントローラ調整のカリキュラム

前項に関連してネットワークに蓄積される知識すなわち入出力特性は、どのような段階を踏んで学習を行ったかに大きく左右される。本章第1節に述べた暫定教示データによるコントローラの初期学習が顕著な効果をもたらしていることも、その理由の一つである。すなわちコントローラの訓練および学習を行う際に、どのようなカリキュラムによって知識（必要な入出力特性）を獲得させれば有効なコントローラを効率的に得ることができるかについて検討する必要がある。

5.3.3 フォワードモデル構築の高速化、精密化

ニューラルネットワークをコントローラとして用いる際に学習の高速化については、前節までに述べたとおりであるが、SONCSにおけるフォワードモデルのように運動モデルとして用いる場合の学習には依然として長い時間を要する。特に出力回帰型のフォワードモデルにおいては、出力の誤差がそのまま入力に反映されてしまうため、精度のよいモデルを得ることは容易ではない。筆者らは第3章にも述べたように、エルマンネットワーク、差分型および出力回帰型を複合したフォワードモデルネットワークを構築する際に4段階に分けた学習を行うことでその高速化、高精度化を試みているが[31]、今後ニューラルネットワークによる時系列情報の学習の高速化に関するより一般的な議論を展開していく必要がある。

5.3.4 全体システムの構造化

前項のフォワードモデル構築の問題にも関連するが、運動あるいは環境のモデルを単体のネットワークで実現することは非常に困難であり、ましてロボットの制御全体を单一のネットワークで行なうことは現実的でない。例えば第4章の航行型海中ロボットの定高度航行問題の例において、SONCSのフォワードモデルを運動のモデル、海底面形状のモデル、海底面からの高度を算出するモデルという3つのネットワークによって構成したように、必要な機能に応じてネットワークを複数用意し、うまく構造化することによってロボット全体の機能を満たすことを考える必要がある。この発想はニューラルネットワークに固執することなく、ルールベースや従来の制御手法など、他の様々な手法と組み合わせ、それぞれを適材適所に用いることによりロボット全体の制御を実現しようとする方向性[28][35]

[36]に通じるものであり、将来的に期待される展開の一つである。

6. まとめ

本論文では、海中ロボットの複雑な運動特性、海中環境下での未知の外乱などに柔軟に対処しうる制御手法として、ニューラルネットワークを用いた学習と自己訓練に基づく“自己生成型ニューラルネットコントローラシステム”(Self-Organizing Neural Net Controller System: SONCS)を提案し、その一般的な構造およびコントローラの生成過程を提示した。また、航行型海中ロボットの深度保持制御に適用することにより、SONCSの具体的な適用方法および自己訓練によるコントローラ調整の実例を示すとともに、可変減衰型動吸振器による振動制御および複雑な海底面上における航行型海中ロボットの一定高度航行制御などへの適用例を通して、SONCSが広い範囲の問題に対して有効に動作することを示した。

自己訓練と学習に基づく制御方式は、本来対象とする実システムを実際に何度も動作させることを通してコントローラの調整を行うために、所望のコントローラが得られるまでにかなりの時間を要することが実用上の問題点であるが、本論で導入した暫定教示データによる学習と、並列処理計算を利用した仮想訓練の手法を取り入れることにより、速やかなコントローラの生成が可能となる。今後、SONCSをより一層実用的な制御システムとして確立するためには、フォワードモデル構築の高速化や随伴ネットを用いた知識の蓄積、再利用などについて研究を進めることが望まれる。

謝辞

本論文をまとめるにあたり、横浜国立大学工学部の森下信助教授、東京大学生産技術研究所（日本学術振興会特別研究員）の黒田洋司氏より貴重なご意見を賜った。ここに深甚なる感謝の意を表します。

参考文献

- [1] 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.
- [2] 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.
- [3] 浦環：“海中ロボットの展開”，日本ロボット学会誌，vol. 11, no. 6, pp. 50-53, 1993.
- [4] 浦環、大坪新一郎：“航行型無人潜水艇に関する研究”，日本造船学会論文集，vol. 162, pp. 117-124, 1987.
- [5] 前田久明、立田真一、本間健一、宮島省吾：“無人無線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.
- [6] J. J. Hopfield: “Neural Networks and Physical Systems with Emergent Collective Computational Abilities,” Proc. Nat. Acad. Sci., vol. 79, pp. 2554-2558, 1982.
- [7] K. Fukushima, S. Miyake and T. Ito: “Neocognitron; a Neural Network Model for a Mechanism of Visual Pattern Recognition,” IEEE Trans. Sys. Man and Cybern., vol. SMC-13, pp. 826-834, 1983.
- [8] D. E. Rumelhart, J. L. McClelland and The PDP Research Group: “Parallel Distributed Processing Volume 1; Foundations,” The MIT Press, Cambridge MA, 1986.
- [9] M. I. Jordan: “Serial Order; a Parallel Distributed Approach.”

- ICS report 8604, Univ. of California at San Diego, 1986.
- [10] M. Kawato, Y. Uno and R. Suzuki: "Hierarchical Neural Network for Voluntary Movement with Application to Robotics," IEEE Cont. Sys. Mag., vol. 8, no. 3, pp. 8-16, 1988.
- [11] K. S. Narendra and K. Parthasarathy: "Identification and Control of Dynamical Systems Using Neural Networks," IEEE Trans. N. N., vol. 1, no. 1, pp. 4-27, 1990.
- [12] D. H. Nguyen and B. Widrow: "Neural Networks for Self-learning CONTROL SYSTEMS," IEEE Cont. Sys. Mag., vol. 10, no. 3, pp. 18-23, 1988.
- [13] 藤井輝夫, 浦環: "潜水艇の自律性とニューラル・コントロールの研究", 生産研究, vol. 41-9, pp. 721-724, 1989.
- [14] 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.
- [15] T. Fujii and T. Ura: "Development of Motion Control System for AUV Using Neural Nets," Proc. IEEE Symp. on Autonomous Underwater Vehicle Technology, Washington DC, pp. 81-86, 1990.
- [16] 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(その1)", 日本造船学会論文集, vol. 168, pp. 275-282, 1990.
- [17] 藤井輝夫, 浦環, 黒田洋司: "コントローラを自己生成する海中ロボット", 第10回海洋工学シンポジウム予稿集, pp. 237-244, 1991.
- [18] 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(その2)", 日本造船学会論文集, vol. 169, pp. 477-486, 1991.
- [19] T. Fujii and T. Ura: "Neural-Network-Based Adaptive Control System for AUVs," Engineering Applications of Artificial Intelligence, vol. 4, no. 4, Pergamon Press, pp. 309-318, 1991.
- [20] T. Fujii and T. Ura: "SONCS: Self-Organizing Neural-Net Controller System for Autonomous Underwater Robots", Proc. IEEE/INNS IJCNN '91, Singapore, pp. 1973-1982, 1991.
- [21] 浦環, 須藤拓: "Unsupervised Learning System for Vehicle Guidance Constructed with Neural Network," Proc. Intl. Symp. on Unmanned Untethered Submersible Tech., Durham NH, pp. 203-212, 1991.
- [22] 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.
- [23] 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)", 日本造船学会論文集, vol. 172, pp. 587-592, 1993.
- [24] 吉田有希, 高橋義明, 黒田洋司: "ニューラルネットワークを用いたROVの自律的制御に関する研究", テクノオーシャンシンポジウム予稿集, pp. 333-338, 1992.
- [25] 黒田洋司, 森下信, 浦環: "ニューラルネットコントローラによる適応的振動制御", 機械学会第68回通常総会論文集, vol. C, pp. 197-199, 1991.
- [26] K. Kuroda, T. Ura, and S. Morishita: "Damping, Controllable Dynamic Damper With Neural Network-Based Adaptive Control System," Proc. IEEE/INNS IJCNN '91, Singapore, pp. 187-192, 1991.
- [27] 黒田洋司, 森下信, 浦環: "可変減衰型動吸振器による適応的振動制御", 日本機械学会論文集C編, vol. 58, no. 550, pp. 1748-1754, 1992.
- [28] 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, 1992.
- [29] 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.
- [30] 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", 計測自動制御学会第14回適応制御シンポジウム予稿集, pp. 77-82, 1994.
- [31] K. Ishii, T. Ura and T. Fujii: "A Feed Forward Neural Network for Identification and Adaptive Control of Autonomous Underwater Vehicles", Proc. IEEE ICNN '94, Orlando FL, pp. 3216-3221, 1994.
- [32] 石川真澄: "ニューラルネットワークによる動的システムの学習と制御", 電気学会論文誌D, vol. 109-4, pp. 225-229, 1989.
- [33] 藤井輝夫, 浦環, 黒田洋司, 菴牧浩二, 能勢義昭: "知的行動能力を有する自律海中ロボットの研究(第1報)", 第11回日本ロボット学会学術講演会予稿集, pp. 695-698, 1993.
- [34] 藤井輝夫, 浦環: "知的行動能力を有する自律海中ロボットの研究(第2報)", 第11回日本ロボット学会学術講演会予稿集, pp. 911-914, 1993.
- [35] 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, 1992.
- [36] 柴田崇徳, 福田敏男: "階層行動アーキテクチャ(適応と学習によるシステムの最適化)", 日本ロボット学会誌, vol. 11, no. 8, pp. 7-13, 1993.



藤井輝夫 (Teruo Fujii)

1964年4月5日生。1988年東京大学工学部船舶工学科卒業。1991年~1993年日本学術振興会特別研究員。1993年東京大学大学院博士課程修了。博士(工学)。同年、東京大学生産技術研究所客員助教授。同助教授を経て現在、理化学研究所基礎科学特別研究員(化学工学研究室)。IEEE, AAAI, 計測自動制御学会等の会員。
(日本ロボット学会正会員)



須藤 拓 (Taku Sutoh)

1965年11月25日生。1990年東京大学工学部船舶海洋工学科卒業。1992年東京大学大学院修士課程修了。工学修士。現在、東京大学大学院博士課程在学中。計測自動制御学会、日本造船学会の会員。
(日本ロボット学会学生会員)



浦 環 (Tamaki Ura)

1948年5月29日生。1972年東京大学工学部船舶工学科卒業。1977年東京大学大学院博士課程修了。工学博士。同年、東京大学生産技術研究所講師。1978年同助教授。1992年同教授。1984年から高等海難審判庁参審員併任。1979年日本造船学会論文賞受賞。1982年報公賞受賞。日本造船学会、日本機械学会、IEEE、計測自動制御学会の会員。
(日本ロボット学会正会員)



石井和男 (Kazuo Ishii)

1969年4月1日生。1991年東京大学工学部船舶海洋工学科卒業。1993年東京大学大学院修士課程修了。修士(工学)。東京大学生産技術研究所研究生を経て、現在、東京大学大学院博士課程在学中。IEEE、計測自動制御学会、日本造船学会の会員。
(日本ロボット学会学生会員)