

モジュラーネットワーク型自己組織化マップを用いた 水中ロボットの運動制御システム

○西田周平(北九州市立大学), 石井和男, 古川徹生(九州工業大学)

A Motion Control System for an AUV using modular network Self-Organizing Map

*Shuhei NISHIDA, The University of Kitakyushu

Kazuo ISHII and Tetsuo Furukawa, Kyushu Institute of Technology

Abstract — Autonomous Underwater Vehicles (AUVs) are attractive tools for maintenance of underwater structures and oceanography. However, there are a lot of problems to be solved. We have been investigated the application of brain-inspired technologies into AUVs.

The motion of AUV is represented by complicated non-linear dynamics in six degrees of freedom with added-mass and hydrodynamic forces, and control systems should be adaptive and robust. In this paper, a new self-organizing controller system for AUVs using modular network Self-Organizing Map (mnSOM) proposed by Tokunaga et al. is discussed. The efficiency of the system is investigated through the simulations.

Key Words: Adaptive Controller System, modular network SOM, AUV

1. はじめに

自律型水中ロボット(AUV: Autonomous Underwater Vehicle)は、海洋科学調査や水中作業のための次世代ツールとして期待されており、実用化が望まれている。AUVの実現には、運動制御、センサ情報の取得、行動決定、衝突回避、自己位置推定など様々な問題がある[1]。しかし、水中という極限環境は人間には容易に想像しがたく、あらかじめロボットに対して様々な状況に対応できるようにプログラミングすることは困難である。したがって人間の負担を軽減するため、AUVの自律性の向上が期待される。ロボットが自身のセンサで状態や環境を把握し、それらに基づいて状況を判断し行動を決定することが望ましい。著者らはニューラルネットワーク(NN: Neural Network)を始めとする生物の情報処理アルゴリズムの仕組みを参考にした学習能力に注目し、水中ロボットの運動制御や行動決定システムへ応用してきた。提案手法は、非航行型の自律型水中ロボット Twin-Burger[2]を用いた実験を通じてその有効性の確認を行っている[3], [4]。

AUVの運動は水中での6自由度の運動であり、複雑かつ非線形な動特性を持っている。また、ミッションの違いによる装備品、搭載機器の変化によるロボット自身の動特性の変化や、潮流の変化によるロボット周囲の環境の変化に起因する運動特性の変化は、制御システムに大きな影響を与える。ロボットが自身や環境の変化に対して適応的に行動することができれば望ましい。文献[3]で提案されたニューラルネットワークによる適応制御手法では、水中ロボットの動特性及び制御器をオンラインで獲得することができるが、一対の動特性と制御器しか持っていないために適応する(動特性と制御器を調整する)過程で、過去における学習によって得た情報の影響は低下していく。つまり、過去において適応していた動

特性及び環境に戻った場合においても再学習する必要がある。常時、ロボットにおいて計測される時系列情報を追加学習しなければならない。より高速に、かつ柔軟に動特性などの変化に適応するには、過去を含めた様々な適応状態を保持しながら、新しい動特性や環境へ適応する行動獲得システムが必要となる。

本研究では、川人らの提案したMOSAIC[5]の概念を参考に、徳永らによって提案されたモジュラーネットワーク自己組織化マップ(mnSOM: modular network Self-Organizing Map)[6]を用いた水中ロボットの自己組織的行動獲得システムを提案する。mnSOMにはSOM[7]の競合層の各ベクトルユニットを多層パーセプトロン(MLP: Multi Layer Perceptron)に置き換えたMLP型mnSOMや、SOMで置き換えたSOM²等があり、関数空間などを取り扱えるように拡張したものである。SOMの特徴である、(1)入力データの内挿の補間を得ることができること、(2)入力空間での距離関係が競合層においても保持される、等の性質を有しており、SOMの一般化といえるアルゴリズムである。提案手法の有効性を検証するため、ロボットの運動特性を競合層のマップとして表現したフォワードモデルマップの取得、フォワードモデルマップに対応したコントローラマップの調整、及びオンラインでの運動特性適応シミュレーションの結果について述べる。

2. mnSOMを用いた制御システム

2.1. mnSOM

本論文において情報処理システムとして導入するmnSOMの概念図をFig.1に示す。左図に示される $F_1(x)$ と $F_2(x)$ は、入力空間におけるある入出力関係を表現しているデータクラスである。競合層には通常のSOMと同様に、例えば六角格子状や正方格子状に

モジュールを配置され、学習の過程で入力空間のデータクラスが表現している関係を教師有り学習によって獲得しながら、並行して評価関数から算出されたクラス間の類似度を基に教師無し学習によって類似した特徴を有するクラスは近接し、特徴が異なるクラスは遠方に配置された競合層マップを得ることができる。学習後、右図に示されるような競合層が得られたとする。競合層において、 $F_1(x)$ と $F_2(x)$ の中間に位置するモジュールは、入力空間においても $F_1(x)$ と $F_2(x)$ の中間に位置する関数を表現しており、入力空間での幾何学的関係が競合層にも保存されたマップが得られる。

mnSOMの適用例として、非線形主成分解析、動的システムのマッピング、及び、自己組織化適応制御器などの有効性が報告されている[8]-[11]。

2.2. ダイナミクスマップの作成

動作環境の変化や動特性の変動、アクチュエータの特性変化や故障を想定、或は、実機により計測し、状態量と操作量の組からなるデータクラスを準備し、学習する。Fig.2-(a)において、ある動特性を表現する時系列データ $S_1(x)$ は白色で示された競合層モジュールが勝者モジュールとして対応し、別の動特性を表現する時系列データ $S_2(x)$ は赤色の競合層モジュールが勝者モジュールとして対応している状況を示している。勝者モジュールが学習した動特性の影響を黄色で示しており、勝者モジュールの間には $S_1(x)$ と $S_2(x)$ から得られた動特性によって補完された動特性を有するモジュール (Forward Model Module: FMM) が得られる。各モジュールの学習係数及び学習回数は同じ値とし、各データクラスに対する勝者モジュールが選択され、学習が収束したと判断された段階で学習を終了し、次の学習段階に移行する。得られた学習結果は、以降、フォワードモデルマップと呼ぶ。

2.3. コントローラマップの作成

第2段階として、作成したフォワードモデルマップを用い、各FMMに適応した制御器を作成する。Fig.2-(b)の上部に示されたコントローラマップの作成においては、競合層における幾何学的な配置は考慮せず、対応するFMMに対してコントローラを適応させるものとする。各コントローラモジュール (Controller Module: CM) に対して制御目標値が与えられる。対応するFMMから得られるロボットの状態量と目標値との偏差量をもとにコントローラマップから操作量が算出され、フォワードモデルマップに送信される。フォワードモデルマップでは、操作量から計算される次の時間ステップの状態量と目標値との誤差をコントローラマップに逆伝播することにより、BP法を用いて制御則の調整を行う。制御目標値、学習係数及び学習回数は各モジュールにおいて同じ値とし、ある程度学習が収束するまで行う。

2.4. ロボットの制御及びオンライン調整

第1段階及び第2段階の学習は、準備されたデータのオフライン学習及び調整であった。第3段階では制御対象であるロボットの制御と並行して、ロボットの動作環境や制御特性の変化に対してオンライン学習による適応を行う。

ロボットのミッション遂行中において、ある一定期間サンプリングされた時系列データ (Fig.2-(c)における S_x) をフォワードモデルマップへ入力する。フォワードモデルマップは動特性推定器として用いられ、最も動特性を表現する勝者モジュール (FMM) が選択される。ロボットの制御には、勝者となったFMMに対応するコントローラモジュールから得られる操作量が採用される。これと並行して、FMMの追加学習による動特性変化への適応、及びFMMの更新に伴うコントローラモジュールの調整が行われる。

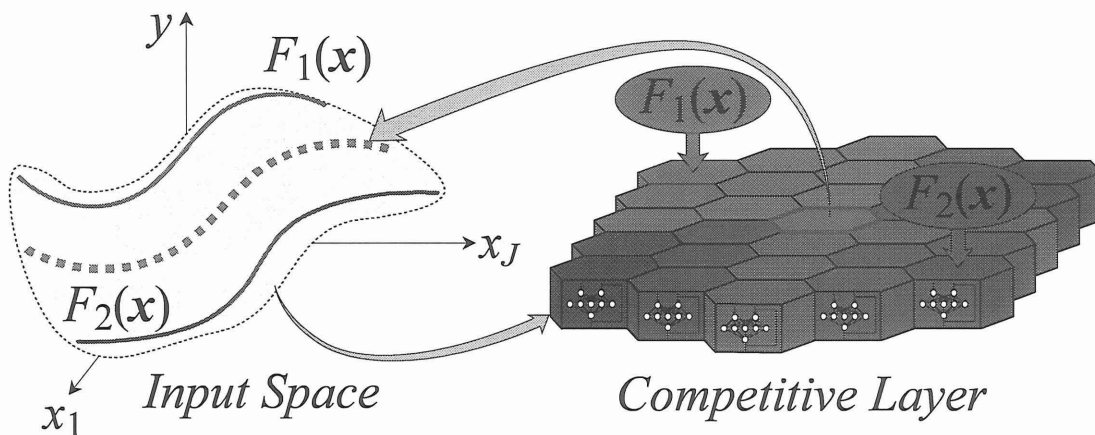


Fig.1 Concept of modular network SOM (mnSOM)

3. オンライン適応シミュレーション

RNN型mnSOMを用いた適応制御システムについて検証するため、参考文献[3]において提案したオンラインコントローラ適応システムを比較対象とし、学習していない時系列データに対する適応能力の評価を行った。比較対象システムにおいて、初期のロボットの動特性として $(M, C) = (80, 25)$ を与えた場合の時系列データを学習することによって、フォワードモデル及びコントローラを構築した。RNN型mnSOMは、式(1)のパラメータ付加質量を含んだ質量 M 、非戦溪流体力に関する係数 C を $(M=80, 90, 100, C=25, 50, 100)$ のように変えた9種類の組み合わせから時系列データを取得し、それらを学習することで得られた制御システムである。


$$F = M\ddot{x} + C\dot{x} \quad (1)$$

教示データとして与えていない $(M, C) = (75, 75)$ 及び $(120, 120)$ として得られた時系列データに対する応答を Fig.3 に示す。 $(M, C) = (75, 75)$ は提案するRNN型mnSOMにおいて学習した領域内のパラメータ設定であり、内挿できることが予想される。 $(M, C) = (120, 120)$ は学習領域外の時系列データである。実線が提案するRNN型mnSOMを用いた適応制御システム、点線が比較対象システムの応答を表している。上図がフォワードモデルの推定誤差、下図がコントローラの制御誤差の推移である。


比較対象システムでは、学習初期においてフォワードモデルの誤差が大きく、フォワードモデルが急速に変更される。フォワードモデルの変更に伴ってコントローラの制御誤差が増加している。コントローラがある程度収束するまでの学習回数は、 $(M, C) = (75, 75)$ へと動特性を変化させた場合は、約20[step]、 $(M, C) = (120, 120)$ のときは約150[step]が必要であった。これは文献[3]における結果と同様の結果を示している。一方、提案システムにおいては、初期動特性よりも与えられた時系列から推定される動特性を最もよく表現しているフォワードモデルモジュールが存在するため、学習初期に若干の調整がみられるものの、推定誤差及び制御誤差とも比較対象システムに比べて良好な適応性能を示している。

4. 結論

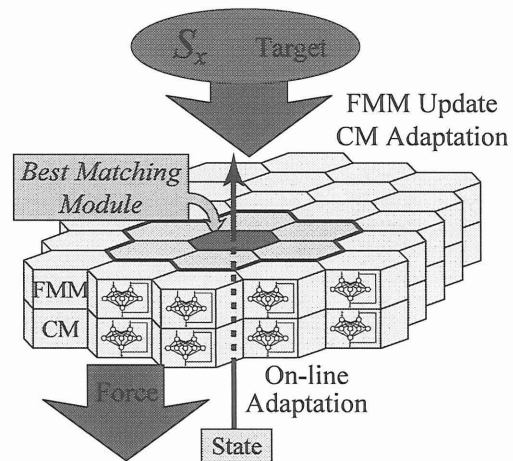
本論文では、RNN型のmnSOMを用いた適応制御手法を提案し、フォワードモデルマップとコントローラマップの作成を行い、適応制御システムを構築した。また、提案した制御システムの適応性能を確認するために、シミュレーションを行った。学習に用いたデータの範囲内、及び範囲外に属するデータのどちらに対しても比較対象システムに比べて良好



(a) Phase 1: Building Forward Model Map



(b) Phase 2: Adaptation of Controller Map using the Forward Model Map



(c) Phase 3: Implementation of the Control Map to Robot Control and On-line Adaptation using the Forward Model Map and the Controller Map

Fig.2 Learning Processes of an Adaptive Controller System using RNN-mnSOM

な適応性能を示している。今後は実機に適応し実験を行っていく予定である。

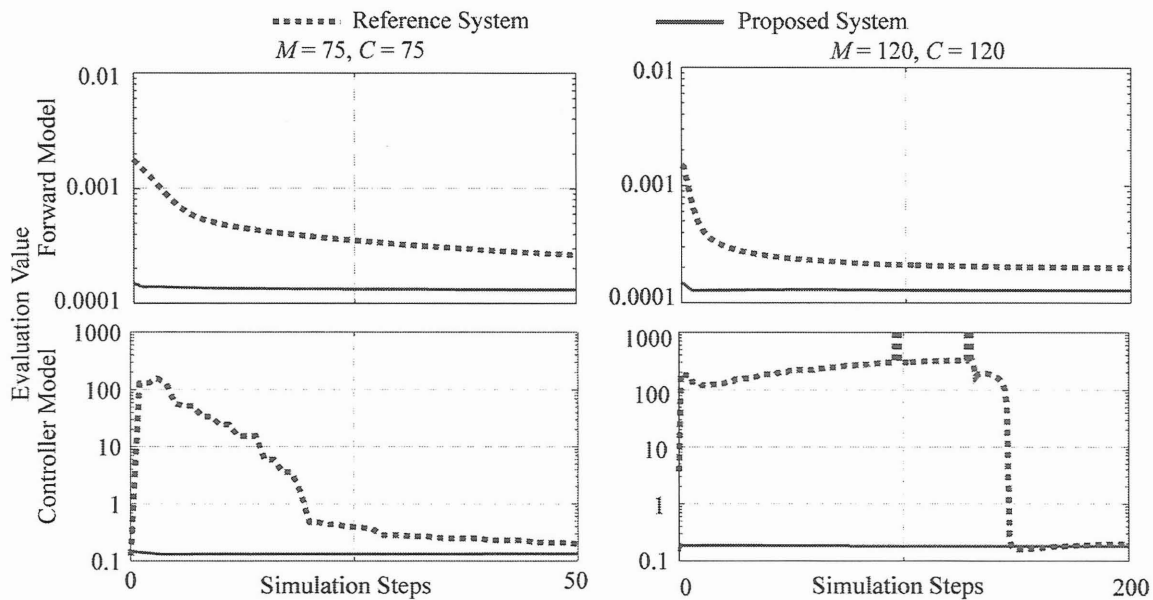


Fig.3 Transition of Evaluation Values

謝辞

本研究の成果の一部は、文部科学省 21 世紀 COE プログラム「生物とロボットが織りなす脳情報工学の世界」(拠点番号 J19) の支援を受けて実施した。ここに感謝の意を表します。

参考文献

[1] 浦環, 高川真一, “海中ロボット総覧”, (1994), 成山堂書店

[2] T. Fujii, T. Ura, H. Chiba, Y. Nose and K. Aramaki, (1993), “Development of a versatile test-bed “Twin-Burger” toward realization of intelligent behaviors of autonomous underwater vehicles,” OCEANS’93, vol.1, pp.1186-1191

[3] K. Ishii, T. Fujii and T. Ura, (1995), “An on-line adaptation method in a neural network based control system for AUVs”, IEEE Journal of Oceanic Engineering, Vol.20, No.3, pp.221-228

[4] S. Nishida, K. Ishii and T. Ura, (2004), “A Self-Organizing Map Based Navigation System for an Underwater Robot”, IEEE International Conference on Robotics and Automation, pp.4466-4471

[5] 川人光男, 銅谷賢治, 春野雅彦, (2000), “ヒト知性の計算神経科学<第 4 回> 多重順逆対モデル(モザイク)

-その情報処理と可能性”, 科学, Vol.70, No.11, pp.1099-1017

[6] K. Tokunaga, T. Furukawa and S. Yasui, (2003), “Modular Network SOM: Extension of SOM to the realm of function space”, 3rd Workshop on Self-Organizing Maps, pp.173-178

[7] T. Kohonen, (1982), “Self-organized formation of topologically correct feature maps”, Biological Cybernetics, vol.43, pp.59-69

[8] T. Furukawa, K. Tokunaga, K. Moroshita and S. Yasui, (2005), “Modular Network SOM (mnSOM): From Vector Space to Function Space”, International Joint Conference on Neural Networks

[9] K. Tokunaga, T. Furukawa, (2005), “Nonlinear ASSOM Constituted of Auto associative Neural Modules”, 5th Workshop on Self-Organizing Maps, pp.637-644

[10] T. Furukawa, T. Tokunaga, S. Kaneko, K. Kimotsuki and S. Yasui, (2004), “Generalized Self-Organizing Maps (mnSOM) for Dealing with Dynamical Systems”, International Symposium on Nonlinear Theory and its Applications, pp.231-234

[11] T. Minatohara, T. Furukawa, (2005), “Self-Organizing Adaptive Controllers: Application to the Inverted Pendulum” 5th Workshop on Self-Organizing Maps, pp.44-48