

研究解説

ニューラルネットワークを用いた 自律型海中ロボットの自己診断システム

A Model Based Diagnosis System for
Autonomous Underwater Vehicles Using Artificial Neural Networks

高井基行*・藤井輝夫*・浦環*

Motoyuki TAKAI, Teruo FUJII and Tamaki URA

本論では、自律型海中ロボットを対象とした自己診断手法を提案する。提案する診断システムは、ロボットに搭載されている状態量計測用のセンサ出力値と、ニューラルネットワークを用いて構成した運動モデルの出力値とを比較することにより、ロボットの運動に関わる搭載機器の故障を検出するものである。また、診断の材料となる情報を能動的に獲得する機能により、初期段階の診断において特定できなかった故障箇所を特定することも可能である。本論において提案するシステムを、自律型海中ロボット“Twin-Burger”に対して構築し、アクチュエータやセンサ自身の故障診断が実際に実行できることを確認した。

1. はじめに

人の手を離れた環境での作業が要求される自律型海中ロボットには、自らの力で思考・判断・学習する事が求められる。ハードウェアの正常な状態を維持し、全体の作業計画を成功させるためには、アクチュエータの故障や回路のショート、センサの異常などの状況をいち早く発見し、故障箇所を特定できるような診断システムの実装が必要である。一例として A. J. Healey¹⁾によるカルマンフィルタとパターンマッチングのためのニューラルネットワークを用いた手法や、A. Orrick ら²⁾による冗長なセンシング情報を用いた故障箇所の検出手法などが提案されている。

これらに対して本研究では、アクチュエータの故障だけでなく、センサの故障にも対応できるように、システムの内部にニューラルネットワークを用いて構成した運動モデルを有し、更に診断の過程で必要な情報を能動的に獲得するメカニズムを備えた自己診断システムを提案する。システムの適用例として、自律型海中ロボットが作業計画前や作業途中に自己診断を行い、異常が発見された場合には作業を停止するなど、速やかな対処を行うことができるシステムの構築を試みる。また自律型海中ロボットのテストベッドである Twin-Burger³⁾にこの自己診断システムを実際に搭載・実験し、その有効性を確認する。

2. 自己診断システムの構成

本論文で提案する自己診断システムは、モデルマッ

*東京大学生産技術研究所 第2部

グ部 (Model Matching Part) 及び診断部 (Diagnosis Part) の二つのサブシステムから構成される (Fig. 1 参照)。モデルマッチング部では、自律型海中ロボットのダイナミクスを表現するモデルをニューラルネットワークを用いて実現し、そのモデルをロボットの正常状態として、ニューラルネットワークの出力とロボットのセンサ出力との比較を行う。診断部ではモデルマッチング部で得られた比較結果から、故障と現象を対応づけるパターンテーブルに基づいて故障部位の診断を行うとともに、作業停止、アクティブ診断あるいは浮上など診断後に行うべき動作を決定する。

自己診断は、ロボットの作業計画前や作業途中において計画的に開始される (Fig. 2 参照)。はじめに、センサからの出力を得るために、ロボットの運動シーケンスの選択及びそれに従ったアクチュエータの駆動を行う。その時センサから得られる信号を用いてモデルマッチングを行い、この比較結果に基づいて診断を実行する。診断する為の情報が十分でない場合には、別の運動シーケンスを採用してアクチュエータを動作させ、診断に必要な新たな情報を獲得するという能動的な手続き (アクティブ診断) を実行する。以上によりロボットが正常であると判断された場合は診断を終了し、作業を継続する。故障が発見された場合には、作業停止などの適切な対処を行う。

2.1 モデルマッチング部

ニューラルネットワークは、柔軟な学習機能を持つことから、海中ロボットのような非線形性を持つシステムのダ

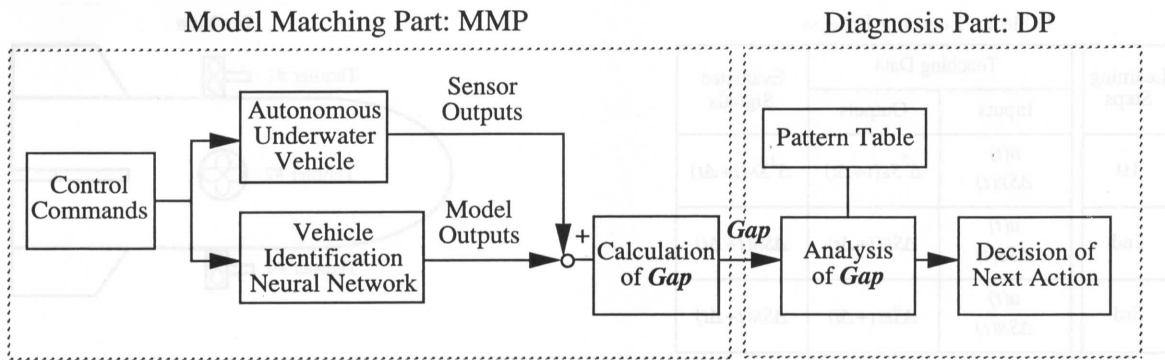


Fig. 1 Architecture of Proposed Diagnosis System

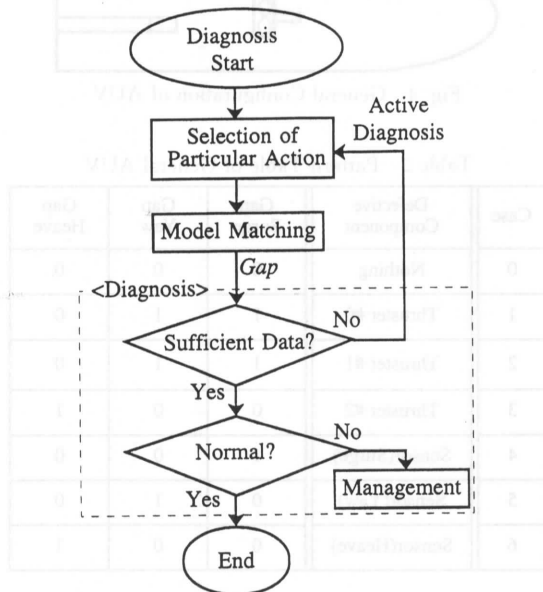


Fig. 2 Flow Diagram of the Proposed System

イナミクスを表現することに適している⁴⁾。モデルマッチング部ではこれを用いて、海中ロボットの正常時のダイナミクスを学習・記憶する。ネットワークの構成にあたっては、次の4点に留意し、Fig. 3に示す構造を用いる。

- 1) 運動モード間の複合的相互関連が強いため、複数入力複数出力の構造とする。
- 2) ロボットの状態量は過去の時系列に影響されるため、回帰的結合 RC_1 を有する Connectionist Model⁵⁾とし、そうした影響をモデル内に蓄える構造とする。
- 3) 学習の収束を速くし、写像関係を精度良く表現するため、出力量が入力量の差分となる差分型ネットワーク⁶⁾とする。
- 4) 運動モデルがセンサの故障に影響されず、操作量のみ依存した出力をするために、入力の状態量は、出力の積分値を回帰的結合 RC_2 を介して与える構造とする。従って、Fig. 2の診断開始時におけるロボットの初期状態とし

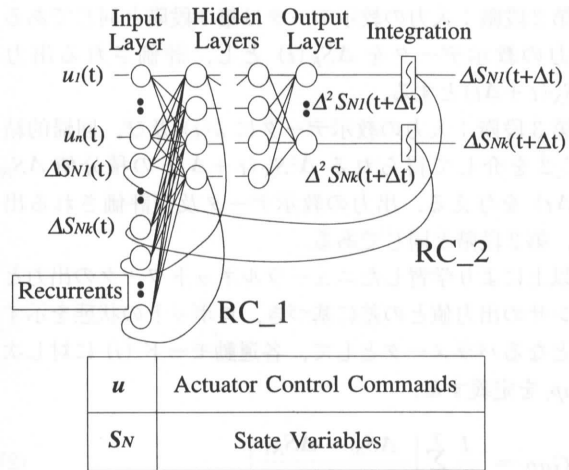


Fig. 3 Neural Network in Model Matching Part

て実ロボットのセンシングデータを与える必要がある。

ニューラルネットの学習は、入出力に対して教示データの組を与え、ニューラルネットワークとの誤差を評価関数により逆伝播 (Error Back Propagation) することによって行われる。教示データを準備するために、例えば、複数運動モードについて同時に行うリミットサイクルなど、正常な動作状態を実現する運動シーケンスを設定し、ロボットを操縦する必要がある。

学習は、Table 1に示す3段階に分けて行うことにより、高精度の写像関係が得られる⁴⁾。ここで、実験においてセンサから得られる状態量及びその差分値を ΔS_E , $\Delta^2 S_E$ 、操作量を u 、ニューラルネットの出力から得られる状態量及びその差分値を ΔS_N , $\Delta^2 S_N$ とする。また、評価関数 E は式(1)にて与える。

$$E = \frac{1}{2} \sum_t \sum_{mode} \{ (Evaluated Signal) - (Teaching Data) \}^2 \quad (1)$$

第1段階：入力の教示データに $u(t)$, $\Delta S_E(t)$ 、出力の教示データに $\Delta^2 S_E(t)$ を与え、評価される出力を $\Delta^2 S_N(t)$

Table 1 Learning Process

Learning Steps	Teaching Data		Evaluated Signals
	Inputs	Outputs	
1st	$u(t)$ $\Delta SE(t)$	$\Delta^2 SE(t+\Delta t)$	$\Delta^2 SN(t+\Delta t)$
2nd	$u(t)$ $\Delta SE(t)$	$\Delta SE(t+\Delta t)$	$\Delta SN(t+\Delta t)$
3rd	$u(t)$ $\Delta SN(t)$	$\Delta SE(t+\Delta t)$	$\Delta SN(t+\Delta t)$

$+\Delta t)$ とする。

第2段階：入力 of 教示データは第1段階と同じであるが、出力 of 教示データを $\Delta SE(t)$ とし、評価される出力を $\Delta SN(t+\Delta t)$ とする。

第3段階：入力 of 教示データに $u(t)$ 及び、回帰的結合 RC_2 を介して得られる $\Delta^2 SN(t+\Delta t)$ の積分値 $\Delta SN(t+\Delta t)$ を与える。出力 of 教示データ及び評価される出力は、第2段階と同じである。

以上により学習したニューラルネットワークの出力と、センサの出力値との差に基づき、ロボットの状態を示す指標となるパラメータとして、各運動モード (i) に対し次の Gap_i を定義する。

$$Gap_i = \frac{1}{T} \sum_t \left| \frac{\Delta S_{Si} - \Delta S_{Ni}}{R_i} \right| \quad (2)$$

ここで ΔS_{Si} , ΔS_{Ni} はモード (i) に対応するセンサとネットワークの出力、 R_i はニューラルネットワーク出力レンジ、 T はリミットサイクルの周期を表す。ニューラルネットワーク出力レンジは ΔS_{Ni} の最大値と最小値の差である。 Gap 値はこれらによって運動モードごとに正規化された値を時間平均したものとなっている。

2.2 診断部

Gap 値をしきい処理し、0 または 1 の二値化したものを状態パターンと呼ぶ。診断部では、この状態パターンとパターンテーブルに基づいて故障箇所の診断・特定を行い、対処するための行動を決定する。

パターンテーブルの作成は、海中ロボットの構成要素に故障が生じた場合に、どのような状態パターンが生じるかを調査・分類することによって行われる。パターンテーブルは海中ロボットに対して固有のものであり、アクチュエータとセンサの位置や特性に依存する。例えば、Fig. 4 に示すような複数のアクチュエータ及び、Surge, Yaw, Heave を検知できるセンサを搭載した一般的な自律海中ロボットを考える場合、Table 2 に示すパターンテーブルが得られる。ただし、ここでは故障が複数同時には生じな




Fig. 4 General Configuration of AUV

Table 2 Pattern Table of General AUV

Case	Defective Component	Gap Surge	Gap Yaw	Gap Heave
0	Nothing	0	0	0
1	Thruster #0	1	1	0
2	Thruster #1	1	1	0
3	Thruster #2	0	0	1
4	Sensor(Surge)	1	0	0
5	Sensor(Yaw)	0	1	0
6	Sensor(Heave)	0	0	1

いことを仮定している。

運動シーケンスに従ってロボットを動作させ、Table 2 のパターンテーブルを用いて診断を行う際に、ケース1と2及び、ケース3と6のように同じ状態パターンが得られてしまい、どちらが原因であるのかの診断ができない場合がある。これらに対しては、故障している可能性のあるアクチュエータのみを用いた別の運動シーケンスにより海中ロボットを操縦し、新しく得られた情報に基づいてアクティブ診断を行う。

Table 2 におけるケース1と2の状態パターンが得られた場合、故障している可能性のある Thruster #0 (もしくは #1) のみを用いた運動シーケンスを行う。この運動によって得られるセンサ情報を基にモデルマッチング及び診断を行い、異常が検出された場合には Thruster #0 (#1) の故障、すなわちケース1 (2) であると診断される。ここで故障が複数同時には生じないという仮定に基づき、排反的に Thruster #1 (#0) は正常であると診断されるが、故障している可能性のあるアクチュエータ全て (Thruster

#0 と #1) についてアクティブ診断を行うものとする。

また、ケース 3 と 6 の状態パターンが得られた場合は、アクティブ診断を行っても故障原因の特定はされず、Thruster #2 と Sensor (Heave) のいずれかの故障という診断結果となる。これは Thruster #2 と Sensor (Heave) が他のアクチュエータやセンサとは独立した作用を行うからである。これを避けるためには、アクチュエータやセンサに冗長性を持たせる必要がある。

以上により何らかの異常の検出や、故障箇所の特がなされた場合には、それまでの作業の中止・浮上及び、ロボットに搭載されたインタフェースを用いた緊急メッセージ表示などの手続きを取る。

3. 自己診断システムの構築

具体的な対象としてテストベッドロボット Twin-Burger³⁾ (Fig. 5) を取り上げ、以上に述べた自己診断システムを実際に構築する。




Fig. 5 Top View of Twin-Burger




Fig. 6 Motion Sequence of Limit Cycle Motion (Using Thruster #0 #1 #2)

Twin-Burger に搭載された速度センサは、Surge・Sway については水に対するロボットの相対速度を計測するプロペラ式流速計 (Flow Meter) である。流速計は光反射式で、正逆両方の流速を感知する。また Yaw については、3 軸周りの角度及び角速度の計測が可能なセンシングシステムである Watson Industry 社製の AHRS (Attitude and Heading Reference System) が装備されている。

3.1 運動シーケンス

Twin-Burger に搭載されたセンサの解像度とスラストの最大出力を考慮し、運動シーケンスを Fig. 6 のように決め、16 秒周期の Surge, Sway, Yaw を並行して行うリミットサイクルとした。また、アクティブ診断においてスラスト単体 (#0 及び #1) を用いて行う運動シーケンスについても、16 秒周期のリミットサイクルを行うものとする。

3.2 運動モデル

運動モデルを表現するため、Fig. 7 に示すニューラルネットワークを用いる。ネットワークの入力は各スラストへの指令値及び各運動モードの速度成分であり、出力は各運動モードの加速度成分である。ニューラルネットワークの学習に用いる教示データは、正常時のロボットを運動シーケンスに従って動作させることにより得られるセンサ出力である。センサ出力の獲得は、Surge, Sway, Yaw を並行して行うリミットサイクル及び、アクティブ診断においてスラスト単体 (Thruster #0 #1) に行うリミットサイクルについてそれぞれ行う。オフラインにて行った学習の結果、出力誤差が Surge: 9%, Sway: 6%, Yaw: 5% となり、Twin-Burger の運動特性を良く表現するネットワークが得られた。

3.3 パターンテーブル

Twin-Burger 固有のパターンテーブルを作成するための調査を行い、Table 3 の結果を得た。Twin-Burger は Surge, Sway, Yaw 及び Heave 方向の動作が可能であるが、

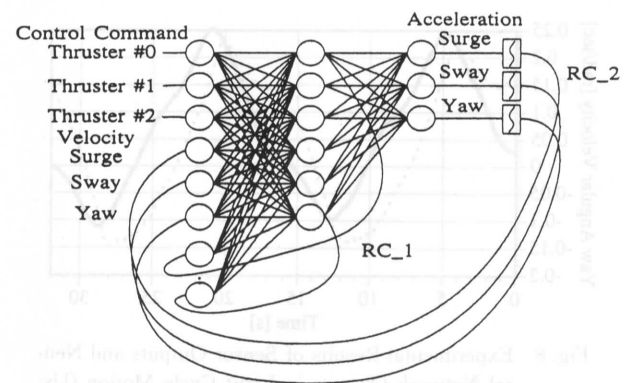


Fig. 7 Neural Network Used in Experiment

Table 3 Pattern Table of Twin-Burger

Case	Defective Component	Condition Pattern		
		Gap Surge	Gap Sway	Gap Yaw
0	Nothing	0	0	0
1	Thruster #0	1	1	1
2	Thruster #1	1	1	1
3	Thruster #2	0	1	0
4	FlowMeter(Surge)	1	0	0
5	FlowMeter(Sway)	0	1	0
6	AHRS(Yaw)	0	0	1

ここでは水平面内の動きに対応する Surge, Sway, Yaw に関する3つの運動モードに限定して考える. ここで例えばケース2において, 状態パターンが (1, 1, 1) となっているのは, Thruster #1 が故障した場合, すべてのモードに対応するニューラルネットワークとセンサ出力との間に差




Fig. 8 Experimental Results of Sensor Outputs and Neural Network Outputs in Limit Cycle Motion (Using Thruster #0 #1 #2)

が生じることを示している.

3.4 アクティブ診断

診断部において, Table 3 におけるケース1と2及び, ケース3と5の状態パターンが得られた場合にはアクティブ診断の手続きを行う.

ケース1と2の状態パターンが得られた場合には, 故障している可能性のある Thruster #0 及び Thruster #1 のみを用いた運動シーケンスによりロボットを順に動作させ, どちらが故障原因であるかの特定を行う. またケース3と5の状態パターンが得られた場合には, この時 Thruster #0 と #1 については正常であるという診断結果及び, Flow Meter (Sway) のセンサ出力に対しては Thruster #0 と #1 からの影響が存在することをを用いてアクティブ診断を行う. すなわち, 正常と診断された Thruster #0 (もしくは #1) のみによる運動シーケンスによりロボッ




Fig. 9 Experimental Results of Gap in Limit Cycle Motion (Using Thruster #0 #1 #2)

トを動作させ、ケース 5 の状態パターンが検出された場合は、Flow Meter (Sway) の故障と診断され、そうでない場合は Thruster #2 の故障 (ケース 3) と診断される。

4. 診断実験

故障状況の例として、Thruster #1 が故障し、出力が仮想的に 75%・50%・25%・0% (停止) に減少した場合の実験を行った。

25% に減少した場合の実験から得られたセンサ出力値を Fig. 8 に、Gap 値の時間変化を Fig. 9 に示す。

これらの結果から、しきい値を Table 4 のように定めることにより、出力が 25% 以下に低下した故障ケースを判別することが可能である。Table 4 には、アクティブ診断において Thruster #0 及び、Thruster #1 のみを用いたりミットサイクルを行う場合のしきい値も示してある。

Twin-Burger ではスラスト軸の伝達系において、マグネットカップリング方式を用いているため、脱調によりスラストの出力レベルがほぼ 0% に落ちてしまう場合がある。Table 4 に示すしきい値を用いる場合、これらの比較的軽い症状を検出することが可能である。ニューラルネットワークの学習の高精度化、学習領域の拡大、及びノイズ対策を含めたセンシング方法の改善を行い、適切なしきい値を決定することにより、比較的軽い症状への対応も可能となる。

Table 4 Gap Thresholds in Motion Sequences

Motion Sequence	Gap Thresholds		
	Surge	Sway	Yaw
Limit Cycle Motion Using Thruster #0 #1 #2	0.15	0.12	0.10
Limit Cycle Motion Using Thruster #0	0.23	0.18	0.10
Limit Cycle Motion Using Thruster #1	0.20	0.15	0.10

5. おわりに

本研究では、自律型海中ロボットの自己診断手法について考え、ニューラルネットワークを用いて表現した運動モデルをシステム内部に持ち、必要に応じて能動的に診断の材料となる情報を獲得する機能を有するシステムを提案した。具体的な海中ロボット Twin-Burger に対してこのシステムを構築し、ロボットの運動に関わるセンサやスラストの故障診断が実際に行えることを確認した。

今後は、故障の種類、程度等に関する議論やニューラルネットワークの精度や学習領域の問題等について検討を加えると同時に、作業中にオンラインで診断を行うことができるような常駐型のシステムへと改良を進める予定である。

(1995年7月18日受理)

参考文献

- 1) A. J. Healey, "A Neural Network Approach to Failure Diagnostics for Underwater Vehicles", Proc. of IEEE Symposium on Autonomous Underwater Vehicle Technology, AUV-92 (1992), pp. 131-134.
- 2) A. Orrick, M. McDermott, D. M. Barnett, E. L. Nelson and G. N. Williams, "Failure Detection in an Autonomous Underwater Vehicle", Proc. of IEEE Symposium on Autonomous Underwater Vehicle Technology, AUV-94 (1994), pp. 377-382.
- 3) 藤井輝夫・浦環・黒田洋司・荒牧浩二・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 (第一報: 汎用テストベッドロボットの開発)", 第11回日本ロボット学会学術講演会予稿集 (1993), pp. 695-698.
- 4) 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 (1995), pp. 429-435.
- 5) D. E. Rumelhart, J. L. McClelland and The PDP Research group, "Parallel Distributed Processing", The MIT Press (1986).
- 6) 須藤拓・浦環, "自己訓練による海中ロボットの定高度航行 (その2: フォワードモデルとコントローラの調整方法の改良)", 日本造船学会論文集, Vol. 171 (1989), pp. 581-586.