

ニューラルネットワークによる 自律型海中ロボットの自己診断システム (その2)

A Model Based Self-Diagnosis System for Autonomous Underwater Vehicles
using Artificial Neural Networks (2nd Report)

高 井 基 行*・浦 環*

Motoyuki TAKAI and Tamaki URA

1. は じ め に

海中海底の調査を行う新しいタイプのロボットとして、自らの判断により自由に泳ぎ回ることのできる自律型海中ロボットが注目されている¹⁾。しかし自律型海中ロボットは命綱を持たないため、その調査活動中の安全を確保する手段を講じる必要がある。安全保守の手法としては、例えば冗長なセンサやアクチュエータを搭載することや、ロボット自身の判断による自己診断システムを搭載することなどが挙げられる。

前報^{2),3)}において筆者らは、ロボットが作業活動に入る直前や途中に、一旦停止し診断動作を行う自己診断システムの提案を行った。この診断システムは、内部に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有し、この運動モデルをロボットの正常状態として記憶している。運動モデルの出力とロボットのセンサ出力とを比較することによってロボットに異常があるか否かの診断を行う。また、必要に応じて診断の材料となる情報を獲得するメカニズム(アクティブ診断)によって故障箇所の特定制を行うことが可能となる。このように、いったん停止して行う診断手続きを本論ではルーチン診断と呼ぶ。

本報ではミッションを中断することなく、調査活動中にもオンラインで診断を行うことが可能な診断システム(ミッション診断と呼ぶ)の提案を行う。また具体的なロボットを対象としてミッション診断を構築し実験を行う。実験結果から、本論で提案する自己診断システムがミッション中に生じた故障を認知し、適切な対処行動へ移行することができることを示す。

2. 条 件 設 定

問題を簡単化するために、以下4つの条件を設定する。

*東京大学生産技術研究所 第2部

(1) 海中ロボットは潮流などの外乱のない環境において動作する。すなわち、ロボットの動特性の変化は、自己の機能の変化に起因するものとする。

(2) 検出するハードウェアの故障は、センサの故障もしくはアクチュエータ(それらのドライバー等の上位部分まで含めた総称)の故障とする。

(3) センサやアクチュエータの状態は、正常もしくはは完全な故障のいずれかであり、一度故障した場合は正常状態に回復しないものとする。

(4) 診断を行う際に生じている故障は、多くとも一箇所までとする。

3. ミッション診断の構造

ミッション診断は、ルーチン診断^{2),3)}と同じ構造を持ち、モデルマッチング部(Model Matching Part)および「診断部(Diagnosis Part)」の二つに分けられる(Fig. 1)。

3.1 モデルマッチング部

モデルマッチング部は、ロボット自身の正常状態として運動モデルを記憶する(Fig. 2)。ロボットの運動特性を数学的にモデル化する手法として、柔軟な学習機能を有し非線形な写像関係を表現することに適するニューラルネットワークを用いる。ニューラルネットワークの構造および学習法に関しては前報²⁾に記す。

運動モデルの入力は、作業活動をする事によるロボットへのコントロール値である。

ロボットと運動モデルの出力の比較の結果を示すパラメータとして g_i を定義する。 g_i は、ロボットに搭載されたセンサの計測すべき物理量 (i) に対応して以下に定義される。

$$g_i = \frac{100}{TR_i} \sum_j |S_{Si} - S_{Mj}| \quad (1)$$




Fig. 1 提案する診断システムの全体構造

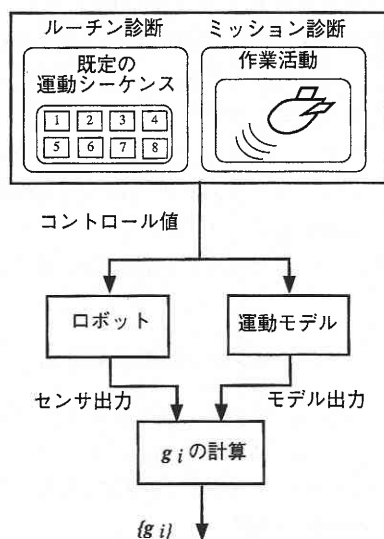


Fig. 2 モデルマッチング部の構造

ここで S_{Si} S_{Mi} は添字 i に対応するセンサとモデルの出力、 R_i はセンサ毎に正規化を行うための定数である。また、あらかじめ決められた定数 T によって時間平均化を行い、100を乗ずることにより単位を [%] とする。このパラメータは次の診断部へと渡される。

3.2 診断部

診断部では、モデルマッチング部から渡された g_i を添字 i ごとにしきい値処理 b_i とする (Fig. 3)。すなわち、しきい値を越えない場合は0、越える場合は1に二値化する。ベクトル $\{b_i\}$ を状態パターンと定義する。

しきい値は、あらかじめロボットの搭載機器に故障を発生させた実験における $\{g_i\}$ の増加量を調査して決定する。

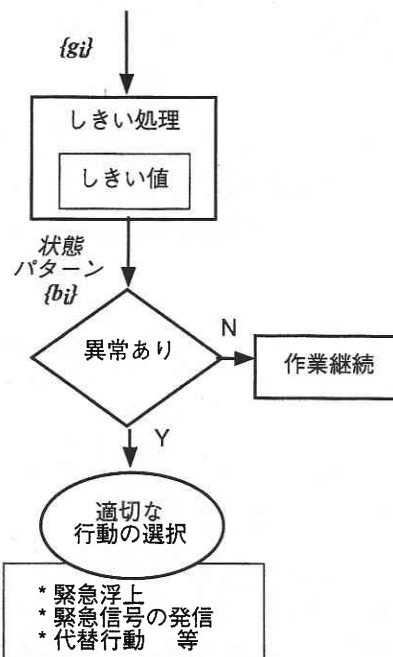


Fig. 3 診断部の構造

作業活動中に、状態パターン $\{b_i\}$ の要素の一つに1が現れると作業を停止する。その後、ルーチン診断に移行し詳細な自己診断を行う。

ルーチン診断の結果、アクチュエータの故障が発見された場合には、浮上用のアクチュエータを用いた緊急浮上など、故障に対応した手続きを選択する。

同じくセンサの故障が発見された場合の対処方法として、故障が発見されたセンサ出力の代わりに運動モデルの出力をコントロールループに組み込み、ロボットの制御を行うことができる (Fig. 4)。すなわち緊急浮上の他に、調査活動の継続やオペレータの下への帰還が可能となる。センサ出力の代わりに運動モデルの出力を用いて制御することを以後、代替行動と呼ぶ。

4. 診断システムの構築


提案する自己診断システムを構築する対象として、自律型海中ロボット Twin-Burger^{4),5)} (Fig. 5) を取り上げる。

ロボットの動作は水平面内の独立した自由度である Surging および Yawing についてのみ取り扱うものとする。したがって、故障検出の対象となる搭載機器はプロペラ式流速計 (Flow センサ)、Yaw 角速度を検出する振動ジャイロ (YawRate センサ) および、アクチュエータの Thruster 0, 1となる。

4.1 モデルマッチング部の構築

モデルマッチング部における運動モデルを作成するため

基本的な制御方法



モデル出力を利用した制御方法




Fig. 4 運動モデルを利用した代替行動




Fig. 5 Twin-Burger 上面図




Fig. 6 センサ出力と学習した運動モデルの出力の比較

には、第1段階から第3段階までの各学習段階^{2), 3)}における複数の組み合わせの学習が必要となる。約40通りの学習係数によりニューラルネットワークの学習を行った。その結果、Fig. 6に示すようにTwin-Burgerの運動特性を精度よく示す運動モデルが得られた。

Table 1 しきい値

{ g_i } Thresholds [%]	
Flow Sensor	YawRate Sensor
15	10

4.2 診断部の構築

4.2.1 故障実験およびしきい値の決定

はじめに、しきい処理のために用いるしきい値を決定する。作業活動中に故障が生じたときの $\{g_i\}$ の増加量を調査するために、Thruster 0 および 1 がそれぞれ故障した実験および、Flow センサと YawRate センサがそれぞれが故障したシミュレーションを行った。この結果からロボットの正常状態と完全な故障状態を必ず区別するしきい値を決定した (Table 1)。

4.2.2 異常発見時の対処方法

$\{g_i\}$ の要素が一つでもしきい値を越えた場合には、即座に作業活動を中断・急停止することとする。その後ルーチン診断を行い故障箇所の特定を行う。その結果 Thruster 0 もしくは 1 の故障と判断された場合は、浮上用 Thruster を用いて緊急浮上を行う。Flow センサもしくは YawRate センサの故障と診断された場合には、運動モデルの出力を用いて代替行動を行うものとする。

5. ミッション診断実験

前章において構築を行ったミッション診断の実験例として、作業中に発生するセンサの故障検出を行う (Fig. 7)。本実験のロボットの作業は、長方形 (4 [m] × 2 [m]) の辺上を時計回りに一周することである。アクチュエータの制御則には前後進位置と方位角の PI 制御を採用する。

ロボットに発生する故障としては、行動開始後約115秒の時点で Flow センサにカバーをし、物理的に信号入力を得られなくなるようにする。実験結果を Fig. 8 に示す。

故障が発生したことは、 g (Flow センサ) が、120秒を越えた頃から増加しはじめ、約130秒の時点で Table 1 で定めたしきい値15 [%] を越え、状態パターンの要素に1が現れることにより判断される。故障を発見したあとは、前報で説明を行ったルーチン診断に移行するが本報ではそれを省略し、代替行動を採用する。すなわち故障が発見された Flow センサの出力の代替として Flow センサに対応する運動モデルの出力を用いることにより、残りの作業を継続する。

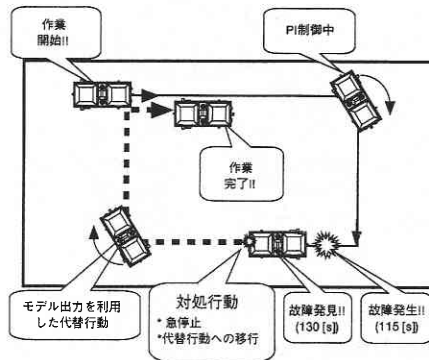


Fig. 7 ミッション診断の実験




Fig. 8 ミッション診断の実験結果

この結果、故障発生から約15秒で故障の発見が行われ若干の時間がかかっているが、これは故障が発生した当初ロボットが静止しており、故障したことがセンサへの影響として検知されなかったことが原因である。また代替行動により作業を継続した結果、ロボットは暴走することなく

所定の作業を完了した。

以上により、ロボットのハードウェアに故障が発生した場合には、パラメータ $\{g_i\}$ が増加することを用いて、作業中の異常を検出することが可能となった。またセンサの異常が検出された場合には、センサの出力の代わりにモデルの出力を制御ループに組み込む代替行動を用いて作業の継続をすることなどが可能となった。

5. おわりに

本研究では、自律型海中ロボットが調査活動を効率的に完遂するための保全要素技術の一つとして、調査活動中の故障を発見し適切な行動をとることが可能な診断システムの構築を目的として研究を進めてきた。

本論で提案を行ったミッション診断のシステムの特徴は以下の2点にまとめられる。

(1) 運動モデルの表現精度を良くするため、これをニューラルネットワークにより構成している(前報²⁾ルーチン診断と共通の特徴)。

(2) 発見された故障状況に応じて、適切な対処行動に移行する能力を有する。対処行動の一つとして、代替行動を用意する。

自律型海中ロボット“Twin-Burger”を対象としてミッション診断の構築をし、診断実験によりその有効性を示した。前報^{2),3)}において提案を行ったルーチン診断と併せて、ロボットの作業前、途中の両者においてロボット自らの判断で異常を発見することが可能となることが示された。

(1996年4月30日受理)

参考文献

- 1) 浦 環・高川真一編著, “海中ロボット総覧”, 成山堂書店, (1994).
- 2) 高井基行・藤井輝夫・浦 環, “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”, 生産研究, 第47巻, 第11号, (1995.11), pp. 48-53.
- 3) M. Takai, T. Fujii and T. Ura, “A Model Based Diagnosis System for Autonomous Underwater Vehicles using Artificial Neural Networks”, Proc. of Ninth International Symposium on Unmanned Untethered Submersible Technology, UUST '95, pp. 243-252, (1995. 9).
- 4) 藤井輝夫・浦 環, “自律型海中ロボットの知的行動の研究—その1:テストベッドロボットの開発とソフトウェア構造—”, 生産研究, 第44巻, 第9号, (1992.9), pp. 437-440.
- 5) T. Fujii, T. Ura, Y. Kuroda, Y. Nose and H. Chiba, “Multi Sensor Based AUV with Distributed Vehicle Management Architecture”, Proc. of IEEE Autonomous Underwater Vehicle Technology, Washington DC, (1992), pp. 73-78.