

# 複雑な形の海底面上を航行する海中ロボットの訓練 ——その 2 : フォワードモデルの改良——

Unsupervised Learning System for Vehicle Guidance Constructed with Neural Network (2nd Report)  
——Improvement in Forward Model Network——

須 藤 拓\*・浦 環\*  
Taku SUTO and Tamaki URA

## 1. はじめに

前報等<sup>1),2)</sup>においては自己生成型ニューラルネットコントローラシステム (SONCS: Self-Organizing Neural-net-Controller System)<sup>3)</sup>を無索無人の航行型海中ロボットの定高度航行に適用した。そこでは手段を教えることなく目的を表現する評価関数を設定し訓練を繰り返す

だけで、地形の変化に対して適応的にコントローラを生成することができることを示した。しかしながら前報のシステムにおいては能力を獲得する速度が遅く、地形の変化に対して適応するために非常に多くの訓練を要した。その原因の一つとしてフォワードモデルが現実を正確に反映していないことが上げられる。そこで本報告ではフォワードモデルの構造に変更を加え、コントローラがより速く適切に調整されるように考える。

制御目的は前報と同様に三角形断面で構成された地形の上を定高度(10m)で航行するものとする (Fig. 1 参照)。

## 2. フォワードモデルの改良

コントローラネットワークが適切に調整されるためにはフォワードモデルネットワークがロボットのダイナミクスやそのまわりの地形情報などを正確に表現できることが必要である。特にコントローラの調整のためには、制御量の変化がフォワードモデルの出力の変化にどのように寄与するかが正確に表現されていることが必要であ

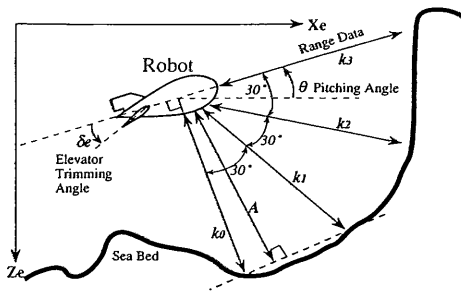


Fig. 1 Configuration of Robot and Direction of Echo Sounders

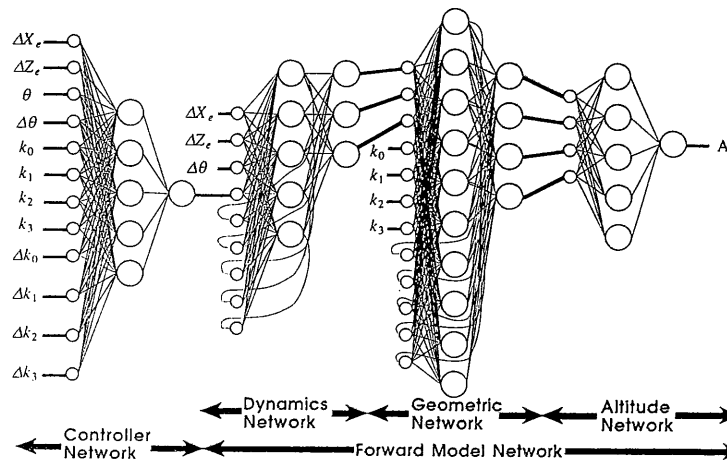


Fig. 2 Overall Network for Constant Altitude Swimming

\*東京大学生産技術研究所 第2部

研 究 速 報

る。しかしながら前報のような単純な形のフォワードモデルの構造では表現することが複雑すぎて、充分な精度のフォワードモデルを単純な教示データの構成では作ることができない。ここでは、(1)フォワードモデルのモジュール化と、(2)各モジュールの出力を次の時間ステップでの値から一つ前の時間すなわち現在の値を引いた時間差分とすることにより精度の向上を考える。

フォワードモデルを複数のモジュールに分割することによって各モジュールの表現すべき写像関係が単純になり、各モジュールの学習自体は容易になる。それによってモジュールを組み合わせた全体の精度が向上すると考えられる。

Fig. 2 は前報のネットワークにおいてフォワードモデルを3つのモジュールに分割したものである。ただし、今回は簡単のために  $\theta$  ついては考えない。一番左はコントローラネットワークで前報とほぼ同じだが第1層目ではシグモイド関数を施さず、ただの分配器となっている。フォワードモデルでは左からロボットのダイナミクスを表現するネットワーク (Dynamics Network)、ロボットが移動することによる地形の変化を表現するネットワーク (Geometric Network)、4つの測距データから高度を計算するネットワーク (Altitude Network) である。フォワードモデルの各モジュールにおいても同じように第1層目は分配器となっている。

次にネットワークの出力の変化の方向と大きさを正確に評価するために、ネットワークの出力を前の時間ステップでの値との差分とする。バックプロパゲーションによる学習では出力の絶対値が教示データと合うように学習が進められるので、単に次の時間ステップの値を出力させたのでは変化量が絶対値に比べて小さい場合には精度がでない。そこで、変化量を出力させた上で前の時間ステップでの値に足し込むことによって次の時間ステップでの値を得る。この方法をとることで出力の変化の方向と大きさがより正確に表現される。以後この型のネットワークを出力差分型ネットワークと呼ぶ。

Fig. 3 は Dynamics Network の I/O 関係である。これは現在の水平方向速度、垂直方向速度、ピッチ角速度




Fig. 3 Structure of the Dynamics Network




Fig. 4 Structure of the Geometric Network




Fig. 5 Structure of the Altitude Network

およびエレベータトリム角を入力とし次の時間ステップでの水平方向速度、垂直方向速度、ピッチ角速度の値を求めるネットワークである。これはさきに述べた出力差分型ネットワークである。内部に回帰的結合を持つので過去の履歴を考慮していることになる。

Fig. 4 は Geometric Network の I/O 関係である。これは現在までの測距データと状態量から次の時間ステップでの測距データを求めるものである。Dynamics Network と同様に出力差分型ネットワークであり、内部に回帰的結合を持つ。

Fig. 5 は Altitude Network の I/O 関係である。このネットワークは測距データと高度の間の静的な関係を表わすだけなので回帰的結合のないコネクショニストモデルである。

### 3. ネットワークの初期化

Fig. 6 はコントローラの初期化およびフォワードモデルの形成の為に用いたデータである。このデータは  $\delta_e$  に関して0.01Hz から1.0Hz までの周波数を含み、サンプル点の総数は約1000点である。なお、 $k_0 \sim k_3$  は最大値を200m とし、無限大を含めてそれ以上の値になった場合には200m として扱っている。

Fig. 7 は Dynamics Network での学習後の結果である。実線が教示データであり、破線はニューラルネットの出力である。両者の差はいずれの出力においても非常に小さくなっており、その結果状態量の変化の方向も大きさ




Fig. 6 Data for Controller Network Initialization & Forward Model Network Construction




Fig. 7 Outputs of the Dynamics Network after Learning

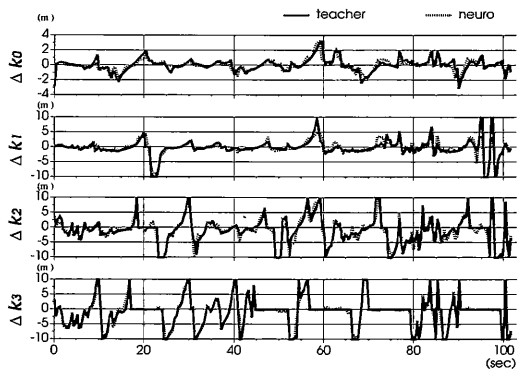


Fig. 8 Outputs of the Geometric Network after Learning




Fig. 9 Output of the Altitude Network after Learning

も良く合っているといえる。Fig. 8は Geometric Networkでの学習後の結果である。ピッチ角の変化により測距ビームの反射が起こらないような非線形性を含んでいるにもかかわらず誤差が小さくなるまで学習が進んでいる。Fig. 9は Altitude Networkでの学習後の結果で、

研究速報  
静的な写像なので誤差が極めて小さくなるまで学習できている。

#### 4. 訓練

評価関数 E については今回はフォワードモデルの出力を高度 A だけとしたので、目標値を  $A_0$  として、

$$E = \sum_n (A - A_0)^2$$

とした。訓練によってこの評価関数の値を小さくしていくことができるので A は  $A_0$  へ近づいていくこととなる。 $A_0$  は前報同様 10m とする。

比較のために前報と同様の 3 種の地形に対して訓練を試みる。Fig. 10は底辺が100m、高さが10mの三角形からなる地形への適応である。初期化しただけのコントローラでは前報同様水平距離で約80m 進んだ所で海底面に衝突してしまうが、その後の訓練では前報では約50回程かかっていた訓練が3回の訓練で同様の性能を得るに至っている。小刻みに振動するのは評価関数の中にピッチ角についての項がないことが原因の一つと考えられる。Fig. 11は底辺が100m、高さが20mの三角形からなる地形への適応である。最上段の図は Fig. 10の3回訓練後のコントローラにより航行させたものである。同

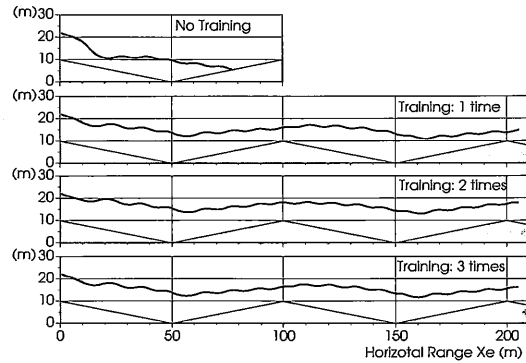


Fig. 10 Training Process over Triangle Ridges 100 m in Width & 10 m in Height




Fig. 11 Training Process over High Triangle Ridges 100 m in Width & 20 m in Height

## 研 究 速 報




Fig. 12 Training Process over Triangle Ridges 50 m in Width & 10 m in Height

様に前報では150回程度かかっていた訓練が2回の訓練で行われている。Fig. 12は底辺が50m、高さが10mの三角形からなる地形への適応である。最上段の図はFig. 11の最初のものと同じコントローラにより航行させたものである。同様に前報では300回程度かかっていたのに比べて6回の訓練で同様の性能を得ており訓練のスピードは非常に速くなっている。

## 5. 結 論

フォワードモデルネットワークの扱う対象が複雑である場合、ネットワークをモジュール化することが有効であることを示した。またコントローラの調整に対して出力差分型ネットワークが有効に働くことを示した。これらの手法を用いればニューラルネットワークを用いた自己生成型のコントローラはより実用的になると考えられる。  
(1992年6月26日受理)

## 参 考 文 献

- 1) 浦 環, 須藤 拓: “複雑な海底面上を航行する海中ロボットの訓練—その1: 自己生成型ニューラルネットワーク制御システムの適用—”, 生産研究, Vol. 43, No. 10 (1991), pp. 28~31.
- 2) Tamaki URA, Taku SUTO: “Unsupervised Learning System for Vehicle Guidance Constructed with Neural Network”, Proc. of 7th International Symposium on Unmanned Untethered Submersible Technology, Durham, New Hampshire (1991), pp 203~212.
- 3) 藤井輝夫, 浦 環, 黒田洋司: “自己生成型ニューラルネットワーク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 (1990), pp. 275~281.