

## ニューラルネットワークと知識ベースを併用した 自動着桟システム\*

正会員 長谷川 和彦\*\*, 正会員 木寺 啓治\*\*\*

### Automatic Berthing Control System Using Network and Knowledge-base

By Kazuhiko HASEGAWA (Member) and Keiji KITERA (Member)

Automatic berthing system for ships using neural network and knowledge-base is developed and confirmed its availability by simulation. Three layer neural network is used and error back propagation method is employed for learning of weighting factors and offsets.

According to the simulation, it is verified to get the successfull results not only for the given pattern as teaching data but also for interporated or exterpolated cases. It is further confirmed to work satisfactorily even under the wind disturbance.

**Keywords :** Automatic Navigation System, Berthing Control, Neural Network control, Knowledge-Based Control

### 1. 緒 言

船舶の自動航行システムを考える上で最も難しいもののひとつに狭水路航行と離着桟がある。大洋航行中はほとんど無人化航行ができたとしても、狭水路や港湾域で多くの人手がかかるのでは、眞の自動化システムとはいえない。

筆者らは、ファジィ推論・制御とエキスパートシステムを用いた船舶の狭水路自動航行システムの開発を行っている([1, 2, 3]など)が、ここでは最後に残された離着桟のうち、まず着桟について桟橋直前までの自力航行の部分の自動化の試みをニューラルネットワークと簡単な知識ベースを用いて行い、シミュレーションによりその有効性を確認した。今後、残された部分の自動化をさらにを行うことにより最終的な自動航行システムの構築も可能となる足がかりが得られたので報告し、諸賢のご批判を仰ぐ次第である。

### 2. 異着桟運動とその自動化の試み

離着桟運動はもちろん、着桟と離桟に分類できる。さらに、着桟運動も航路からはずれ減速変針しながら桟橋

の直前にアプローチする領域(大和ら<sup>7</sup>)にならって、Phase 1 と呼ぶことにする)と桟橋直前から接岸までの領域(同じく大和ら<sup>7</sup>)のPhase 2 に分けることができる。Phase 1 では主に自船の主機と舵を使って制御するのに対し、Phase 2 では、多くはタグボート、フェリー等においてはサイドスラスターを併用して制御するのが普通である。離桟も同様である。

この自動化を行う試みがいくつかなされている。小瀬ら<sup>4</sup>は規範モデル(航跡と針路とその微分値)を与え、実際の航跡と針路の誤差をフィードバック及びフィードフォワード制御する方法を提案した。しかし、なんらかの原因で規範モデルから大きくはずれたり、着桟制御を開始する時点で規範モデルと異なった点に到着した場合には充分な効果が期待できないことが予想され、従来型の制御手法には限界があると思われる。

小山ら<sup>5</sup>は離着桟運動全体を知識ベースシステムとして整理し、このうち、着桟のPhase 2 を最適レギュレータ問題として定式化して外乱などの影響にも耐える制御結果をシミュレーションにより得た。しかし、やはり従来型の制御手法では表現できない部分があったり、トラッキング問題としてとらえたPhase 1 とのスムーズな接合が難しいなどの理由により統合化されたシステムとしては完成していない。

そこで、従来型でない制御手法に着目した研究が行われている。高井ら<sup>6</sup>は予見ファジィ制御手法を用いてタ

\* 平成5年5月28日 関西造船協会春季講演会において講演  
原稿受付平成5年6月16日

\*\* 大阪大学工学部

\*\*\* 日本IBM(株), 研究当時大阪大学工学部

グポート支援による離着桟のPhase 2の自動化を試みた。一方、大和ら<sup>7)</sup>はニューラルネットワークを用いた着桟制御の試みを行い、基本的ながらファジィ制御やニューラル制御による離着桟自動化の可能性が示された。

しかし、大和ら<sup>8)</sup>はその後の研究の方向を知識ベース駆動型の制御システムに転換しており、ファジィ制御や

ニューラル制御による離着桟自動化の試みが十分検討されたとはいえない。

そこで本報では、大和ら<sup>7)</sup>にならってニューラルネットワークを用いた着桟(Phase 1)制御とそのシミュレーションを行い、その結果について詳細な検討を試みた。

### 3. ニューラルネットワークを用いた着桟制御

ニューラルネットワークとは、人工的に構築された神経細胞のモデルであり、人間や動物同様に学習効果があることから人工知能研究の一端として広い分野で応用されるに至った新しい手法である。

詳細はすでに成書も多く出ているのでそちらに譲るが、文字認識、パターン認識などその知識が陽に表現できない分野で多くの実用的効果を上げている。

他方、制御などの分野では意外と適用例が少ない、浦ら<sup>9)</sup>は一連の研究でニューラルネットワークのROV(無索無人海中ロボット)制御を行っているが、結論的には状態がパターン認識的に把握しやすく、かつ従来型の制御則が見つかりにくいシステムでの適用が有効と思われる。

本報では、Fig. 1, Fig. 2に示す座標系を用いて、Fig. 3に示す3層のニューラルネットワークを用いた。なお、Fig. 3において、 $\xi$ ,  $\eta$ はFig. 2に示すように着桟地点に原点をおいた空間固定座標からみた船体重心のそれぞれの軸方向の座標、 $x$ ,  $y$ は反対に船体固定座標からみた着桟地点のそれぞれの軸方向の座標である。大和ら<sup>7)</sup>との違いは $x$ ,  $y$ を追加した点と逆に風向、風速の要素を入力層からはずした点である。この影響については後述する。他の入力についてはFig. 1に示すとおりである。

教師データとしてはFig. 4に示す7つのパターンか

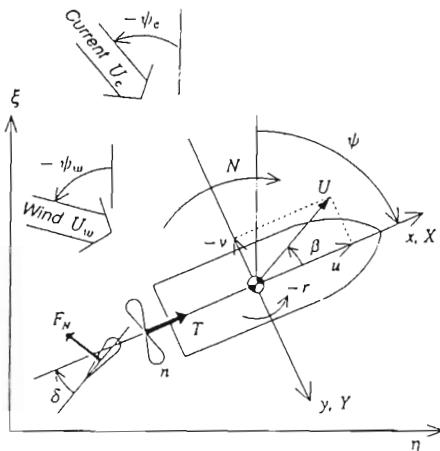


Fig. 1 Coordinate system for ship dynamics

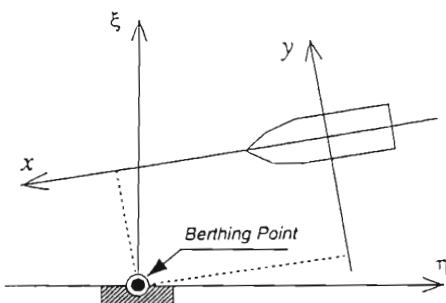


Fig. 2 Coordinate system for berthing

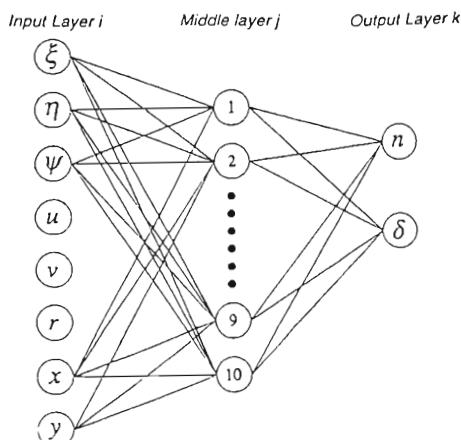


Fig. 3 Three layer neural network

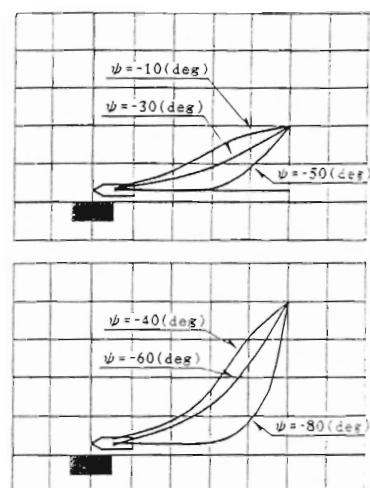


Fig. 4 Patterns given for teaching data creation

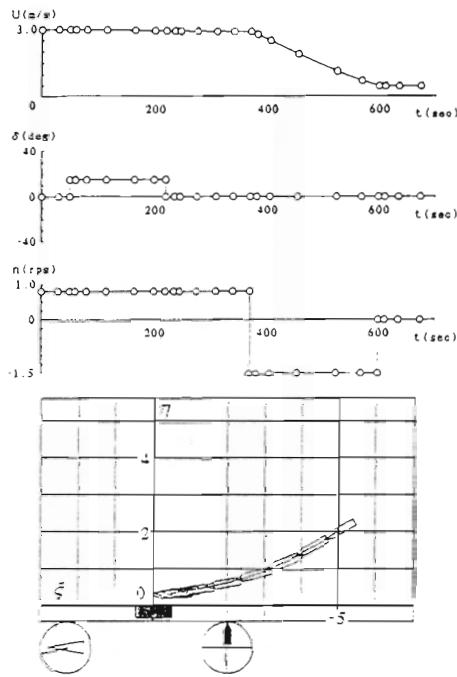


Fig. 5 An example of given teaching data

らの着棧を手動で行ったものを用い、誤差逆伝播(Error back propagation)学習法<sup>10)</sup>を用いて学習を行い、各ニューロン間の結合係数とオフセットを決めた。Fig. 5に与えた教師データの一例(図中の○印)を示す。なお、図中の座標値は船長で無次元化して表示している。各ニューロンの出力の応答関数には出力を滑らかに変化させるため傾斜係数が2の傾斜のゆるやかなシグモイド関数を用いた。詳しくは付録に記す。なお、学習にあたっては、結合係数とオフセットの初期値を乱数で与え、学習が進むごとにその修正値をそのまま用い、

$$A = 0.6 + 0.02 \times n$$

なる修正係数 $A$ を乗じて用いた。ただし、 $n$ は学習回数だが、修正係数が1になったら、0にリセットするいわゆる修正モーメント法を用いた。

さらに、Phase 1の最終段階では簡単な知識ベースを併用してPhase 2へのスムーズな移行を計った。この知

Table 1 Knowledge-base used for berthing control

- Reversing ( $n = -1.5$  rps for the given ship)  
if  $U > 0.5$  m/s      at  $x/L < 1.0$
- Take hard starboard (with boosting, optional)  
if  $\psi < -10$  deg      for  $1.5 < x/L < 2.5$
- Take port ( $\delta = -15$  deg) (with boosting, optional)  
if  $r > 0.1$  deg/sec      for  $1.5 < x/L < 2.5$

識ベースは、ニューラルネットワークより優先して作動するようになっており、フィードフォーワード的な作用を果たす。ここで用いた知識ベースをTable 1に示す。

#### 4. 低速時の操縦運動数学モデル

本システムの有効性を確かめるため、シミュレーション計算を行ったが、その際、検討しなければならないのは船の操縦運動モデルである。離着棧運動においては前進速度に比べて横流れ速度が大きく、通常のいわゆるMMGモデルでは十分な精度が得られない。

そこで、低速時の操縦運動モデルを採用する必要がある。すでに、いくつかのモデルが提案されているが、ここでは小瀬ら<sup>11)</sup>のモデルと船長が304mのタンカーとその係数をそのまま借用して用いた。用いたモデルとその係数については文献<sup>11)</sup>とともに文献<sup>12)</sup>を参照いただきたい。

#### 5. シミュレーション結果

まず、教師データと同じ状態のシミュレーション結果の一例をFig. 6に示す。教師データとは少し違った操作をしているが、ほぼ教師データと同じ航跡をたどって着棧している。ここで図のタイトルにあるケースはスタート時の座標( $L$ は船長)、カタログ及び進入角( $\psi$ )を示す。

また、教師データにないハターンでのシミュレーション結果の例として、初期位置は同じだが進入角が違うケース(Fig. 7)，初期位置も進入角も違うケース(Fig. 8)をそれぞれ示す。いずれの場合も、教師データとの関連を

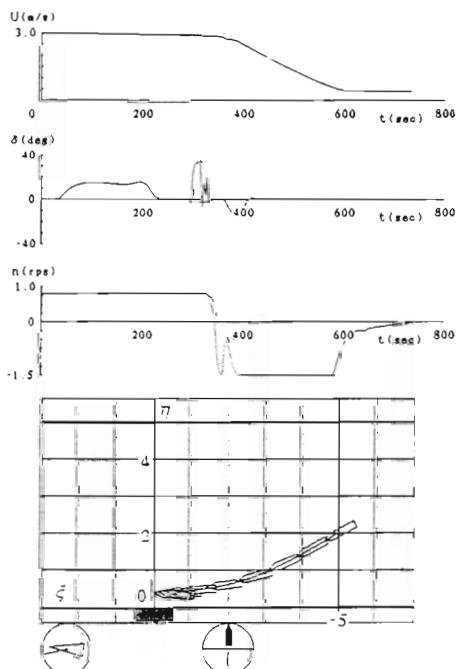


Fig. 6 Simulation of the case:  $(5L, 2L)$ ,  $\psi = -30(\text{deg})$

探しつつうまく制御していることがわかる。さらに極端な例として初期位置は同じだが進入角が全然反対方向を向いているケースを Fig. 9 に示すがニューラルネットワークのパターン分析能力が優れていることを表す好例である。

以上のケースは風や潮流のない条件下であったが、最後に、風の外乱が加わった場合のシミュレーション結果

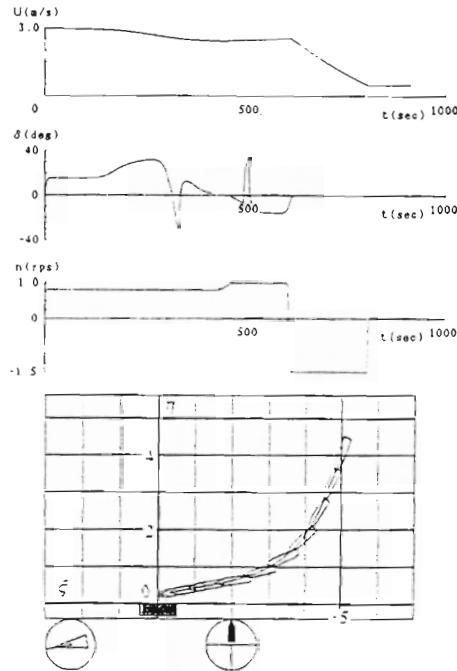


Fig. 7 Simulation of the case :  $(5L, 4L)$ ,  $\psi = -70(\text{deg})$

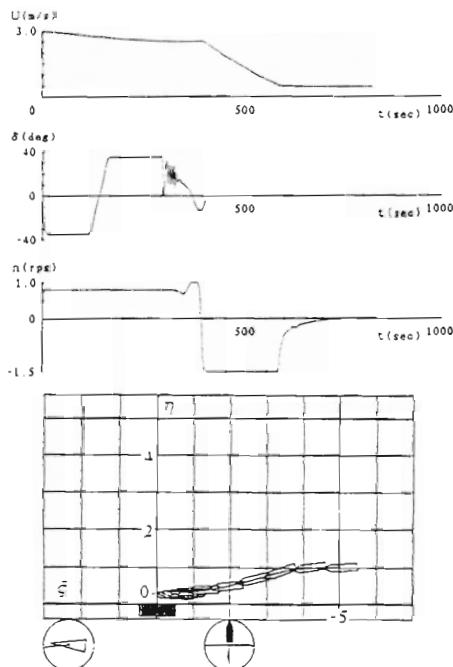


Fig. 8 Simulation of the case :  $(5L, 1L)$ ,  $\psi = 0(\text{deg})$

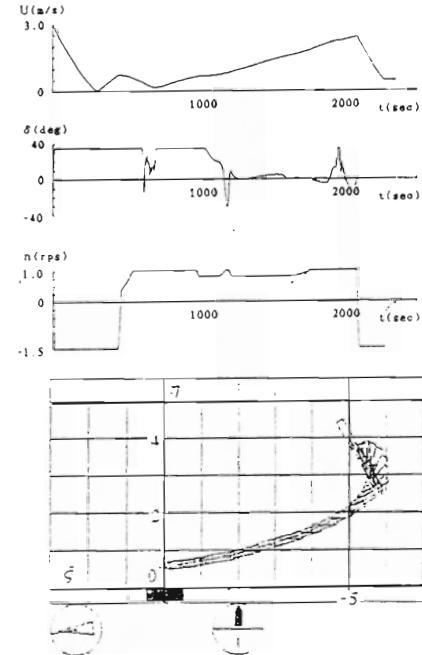


Fig. 9 Simulation of the case :  $(5L, 4L)$ ,  $\psi = -120(\text{deg})$

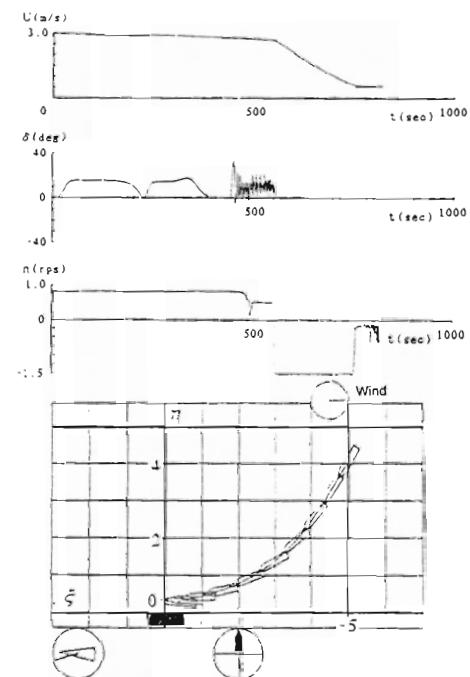


Fig. 10 Simulation of the case :  $(5L, 4L)$ ,  $\psi = -60(\text{deg})$  with fair wind of  $10\text{m/s}$

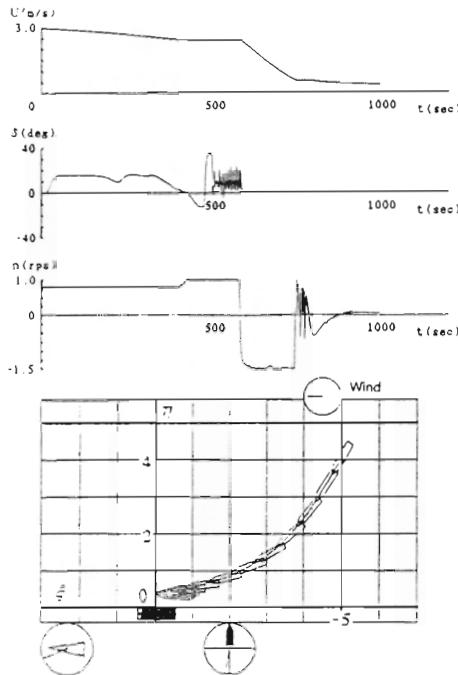


Fig. 11 Simulation of the case :  $(5L, 4L)$ ,  $\phi = -60(\text{deg})$  with contrary wind of  $10\text{m/s}$

の一例を Fig. 10 と Fig. 11 に示す。風の影響を考慮して操舵及び回転数制御を手加減していることがわかる。なお、大和ら<sup>7</sup>はニューラルネットワークの入力層に風速と風向を入れているが、Phase 1 においては風の影響を検討していない。Fig. 10 と Fig. 11などを参照すると Phase 1 においては必ずしも風速と風向を入力しなくとも制御可能と思われる。ただし、今回は検討していない Phase 2 においては相対的に風の影響が大きいので入力層に加えた方がよいと思われる。潮流の影響なども含めて今後の検討事項である。

## 6. 結 言

本研究で得られた主な結論を述べる。

1. 船の着棧制御に適したニューラルネットワークを構築した。
2. Phase 1 から Phase 2 へのスムーズな移行を計るために簡単な知識ベースを併用した。
3. シミュレーションの結果、幅広い範囲、外乱下でニューラルネットワークが着棧制御に有効であることがわかった。

## 謝 辞

本研究を遂行するに当たり、広島大学の小瀬邦治教授、海上保安大学校の日當博喜助教授には低速時の操縦運動モデルの係数の提供を得た。紙面を借りて厚くお礼申し上げる。

## 参 考 文 献

- 1) 長谷川和彦、上月明彦：Fuzzy 制御による自動避航システムに関する研究、関西造船協会誌、第205号、pp.1-10, 1987年6月。
- 2) 長谷川和彦、上月明彦他：船舶自動航行ファジィエキスパートシステム(SAFES)，日本造船学会論文集，第166号，pp.445-452, 1989年12月。
- 3) 長谷川和彦、藤田陽一：船舶自動航行エキスパートシステムの狭水路航行アセスメントへの適用、関西造船協会誌、第220号(投稿中)，1993年9月。
- 4) 小瀬邦治、福戸淳司他：船の自動離着棧システムに関する研究、日本造船学会論文集、第160号、pp.103-110, 1986年12月。
- 5) 小山健夫、金 雁、金 奎煥：船の自動離着棧のシステム論的考察(第1報)，日本造船学会論文集、第162号、pp.201-210, 1987年12月。
- 6) T. Takai and H. Yoshihisa : "An Automatic Manoeuvring System in Berthing", Prof. of Eighth Ship Control Systems Symposium, Vo.2, pp.1-13, The Hague, Oct., 1987.
- 7) H. Yamato, H. Uetsuki and T. Koyama : "Automatic Berthing by the Neural Controller", Proc. of Ninth Ship Control Systems Symposium, Vo.3, pp.3.183-201, Bethesda, U.S.A., Sep., 1990.
- 8) H. Yamato, T. Koyama and T. Nakagawa : "Automatic Berthing Usingthe Expert System", Proc. of Workshop on Artificial Intelligence Control and Advanced Technology in Marine Automation (CAMS'92), pp.173-183, Genova, Apr., 1992.
- 9) 藤井輝夫、浦 環：ニューラル・ネットによる潜水艇の運動制御、日本造船学会論文集、第166号、pp.503-511, 1989年12月。
- 10) D.E.Rumelhart *et al.* : "Parallel Distributed Processing", Vol. 1, 2, The MIT Press, 1986.
- 11) 小瀬邦治、日當博喜他：低速で航行する船の操縦運動モデルについて、日本造船学会論文集、第155号、pp.132-138, 1984年6月。
- 12) K. Hasegawa, K. Kitera : Mathematical Model of Manoeuvrability at Low Advance Speed and its Application to Berthing Contro.", Proc. of The 2nd Japan-Korea Joint Workshop on Ship and Marine Hydrodynamics", pp.144-153, Osaka, June, 1993.

## 付 錄

### A.1 ニューロン理論

神経細胞(ニューロン)の人工的なモデルをユニットと呼ぶことにする。今回用いるのは非常に簡略化されたモ

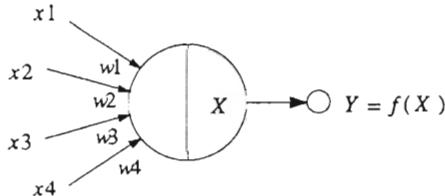


Fig. A1 Simplified neuron model

デル(Fig. A1)であり、入力と出力は次式で示す関係にある。

$$X = \sum_i w_i \cdot x_i \quad \dots \dots \dots \text{(A.1)}$$

$$y = f(X) \quad \dots \dots \dots \text{(A.2)}$$

ここで、 $x_i$ は入力、 $w_i$ はユニットへの結合加重、 $f(X)$ は出力 $y$ の応答関数である。この応答関数は、神経細胞がある興奮状態以上になると次のニューロンに刺激を伝達することを模擬するものであります。ステップ関数状のものが種々提案されているが、一般には次のシグモイド関数(Fig. A2)が用いられている。

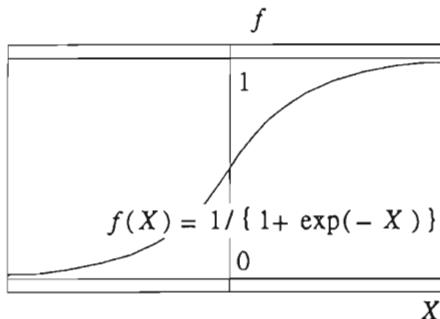


Fig. A2 Sigmoid function

$$f(x) = \frac{1}{1 + \exp(-2x/u_0)} = \frac{1 + \tanh(x/u_0)}{2} \quad \dots \dots \dots \text{(A.3)}$$

$$f'(x) = 2f(x) \frac{1 - f(x)}{u_0} \quad \dots \dots \dots \text{(A.4)}$$

上に示すようにこの関数はその微分がもとの関数自身で表現できるので次に示す学習のアルゴリズムで扱いやすい。

### A.2 誤差逆伝播法

上述ユニットを組み合わせ、Fig. A3のように構成し

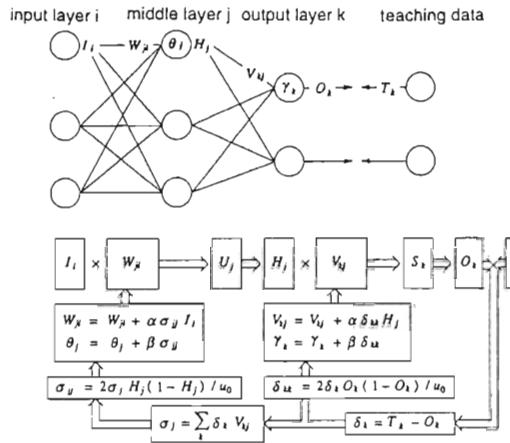


Fig. A3 Three layer neural network and error back propagation method

たものを3層ニューラルネットワークという。左列が入力層、中央列が中間層、右列が出力層である。今、ある状態の時出力層の興奮状態がわかっているとし、それを教師信号として与え、出力がそなたるよう結合加重を変化させるアルゴリズムのひとつとして誤差逆伝播法がある。

ここでは、この方法について説明する。

Fig. A3において、

$$U_j = \sum_i W_{ji} I_i + \theta_j \quad \dots \dots \dots \text{(A.5)}$$

$$H_j = f(U_j) \quad \dots \dots \dots \text{(A.6)}$$

$$S_k = \sum_j V_{kj} H_j + \gamma_k \quad \dots \dots \dots \text{(A.7)}$$

$$O_k = f(S_k) \quad \dots \dots \dots \text{(A.8)}$$

ここで、

$I_i$  入力層ユニット*i*の出力

$H_j$  中間層ユニット*j*の出力

$O_k$  出力層ユニット*k*の出力

$T_k$  出力層ユニット*k*に対する教師信号

$\theta_j$  中間層ユニット*j*のオフセット

$\gamma_k$  出力層ユニット*k*のオフセット

$W_{ji}$  入力層ユニット*i*と中間層ユニット*j*の結合係数

$V_{kj}$  中間層ユニット*j*と出力層ユニット*k*の結合係数

いま、出力における教師信号との誤差を $\delta_{kk} = T_k - O_k$ 、その2乗誤差を $E_p$ とおき、 $E_p$ を最小化する問題を考える。

$$E_p = \sum_k (T_k - O_k)^2 / 2 \quad \dots \dots \dots \text{(A.9)}$$

$$\frac{\partial E_p}{\partial O_k} = -(T_k - O_k) = -\delta_{kk} \quad \dots \dots \dots \text{(A.10)}$$

一方、(A.4), (A.7)式の関係より

$$\begin{aligned}\frac{\partial O_k}{\partial V_{kj}} &= \frac{\partial O_k}{\partial S_k} \cdot \frac{\partial S_k}{\partial V_{kj}} \\ &= f'(S_k) \cdot H_j = \eta_1 \cdot O_k \cdot (1 - O_k) \cdot H_j \\ &\dots\dots\dots(A.11)\end{aligned}$$

ここで、 $\eta_1$  は定数、

よって、

$$\begin{aligned}\frac{\partial E_p}{\partial V_{kj}} &= \frac{\partial E_p}{\partial O_k} \cdot \frac{\partial O_k}{\partial V_{kj}} \\ &= -\eta_1 \cdot \delta_{kk} \cdot V_{kj} \cdot (1 - O_k) \cdot H_j \dots\dots\dots(A.12)\end{aligned}$$

となり、 $E_p$  を減少させるための結合係数  $V_{kj}$  の更新値  $\Delta V_{kj}$  は、

$$\begin{aligned}\Delta V_{kj} &= -\alpha_2 \frac{\partial E_p}{\partial V_{kj}} \\ &= \alpha_2 \cdot \eta_1 \cdot \delta_{kk} \cdot O_k \cdot (1 - O_k) \cdot H_j \\ &= \eta_2 \cdot \delta_{kk} \cdot O_k \cdot (1 - O_k) \cdot H_j \dots\dots\dots(A.13)\end{aligned}$$

ここで、 $\alpha_2$  は定数、 $\eta_2 = \alpha_2 \cdot \eta_1$

また、誤差として

$$\begin{aligned}\delta_k &= -\frac{\partial E_p}{\partial S_k} = -\frac{\partial E_p}{\partial O_k} \cdot \frac{\partial O_k}{\partial S_k} \\ &= \delta_{kk} \cdot O_k \cdot (1 - O_k) \dots\dots\dots(A.14)\end{aligned}$$

を使うと、

$$\Delta V_{kj} = \eta_2 \cdot \delta_k \cdot H_j \dots\dots\dots(A.15)$$

と書き直すことができる。入力層から中間層への結合係数  $W_{ji}$  の更新値  $\Delta W_{ji}$  に対しても同様に計算することができる。

$$\begin{aligned}\frac{\partial E_p}{\partial W_{ji}} &= \left( \frac{\partial E_p}{\partial S_k} \cdot \frac{\partial S_k}{\partial H_j} \right) \cdot \frac{\partial H_j}{\partial U_j} \cdot \frac{\partial U_j}{\partial W_{ji}} \\ &= \left( \sum_k (-\delta_k) \cdot V_{kj} \right) \cdot f'(U_j) \cdot I_i \\ &= -\sum_k \delta_k \cdot V_{kj} \cdot H_j \cdot (1 - H_j) \cdot I_i \dots\dots\dots(A.16)\end{aligned}$$

となる。ここで、 $\sigma_j$  を

$$\frac{\partial E_p}{\partial W_{ji}} = -\sigma_j \cdot I_i \dots\dots\dots(A.17)$$

$$\begin{aligned}\sigma_j &= -\frac{\partial E_p}{\partial U_j} = -\frac{\partial E_p}{\partial O_k} \cdot \frac{\partial O_k}{\partial S_k} \\ &= \sum_k \delta_k \cdot V_{kj} \cdot H_j \cdot (1 - H_j) \dots\dots\dots(A.18)\end{aligned}$$

とおくと

$$\begin{aligned}\Delta W_{ji} &= -\eta_3 \frac{\partial E_p}{\partial U_j} \\ &= -\eta_3 \cdot \sigma_j \cdot I_i \dots\dots\dots(A.19)\end{aligned}$$

となる。ここで、 $\eta_3$  は定数。

これまでの式は、1つの入出力の値の組に対して誤差  $E_p$  を最小化させるものであったが、複数の組の入出力に対して学習させる場合、

$$E = \sum_p \sum_k (T_{pk} - O_{pk})^2 / 2 = \sum_p E_p \dots\dots\dots(A.20)$$

のような誤差関数を求める必要があり、各組の入出力  $p$  での誤差  $E_p$  を徐々に小さくし、全体として誤差関数  $E$  を極小化する。

またオフセット  $\theta, \gamma$  は、常に 1 を出力するユニットとの結合係数として、 $W, V$  とまったく同様に学習できる。

## 討 論

### 【討論】 (日立造船(株)技研) 一色 浩

- 講演論文集の Fig. 7 を見ると舵角  $\delta$  に高周波の振動が出ているところがありますが、これをどう考えますか？また、実際的にはどう対処すれば良いですか？
- 講演論文集の Fig. 3 を見ると人力層に  $\xi, \eta$  と  $x, y$  の両方がありますが、この違いは何ですか？
- 教師データを手動で発生させるとのことですが、詳しく説明いただけませんか？またその際の問題は何ですか？
- $\xi, \eta$  は実際には何で計測するのでしょうか？充分な精度の計測法があると考えて良いでしょうか？

### 【回答】

- Fig. 8 (講演論文集の Fig. 7) や Fig. 10 (講演論文集の Fig. 9), Fig. 11 に見られる舵角や回転数の高周波の振動はニューラルネットにおけるパターンマッチが不安定なためと思われます。問題はその原因ですが、Fig. 5 に示したように教師データは操舵や逆転指令などが ON-OFF 的に変化しています。しかし、そのタイミングは絶対そこでないといけないわけではなく、操船者が適当に判断して決めたものです。しかも、多少のタイミングのずれはあとで補正が可能であり、操船者はそのタイミングをあまり重要視していません。たとえば、自動車をバックで駐車させるときのハンドルを切るタイミングを考えてもらえばわかると思います。初心者は「そのタイミング」をはずすとどう頑張ってもうまくいかないものですが、ベテランになるとあとで補正していることに気づくでしょう。今回は Fig. 4 に示したたった 7 つのパターンのしかもそのただ 1 回ずつの試行例を教師信号として用いました。当然、7 つのパターンの間でその切り返しのタイミングや操作量は「きれいな関係」になってしまいません。ニューラル

ネットワークはその一見でたらめに近い関係からどの7つのパターンでももっとも教師データに近い出

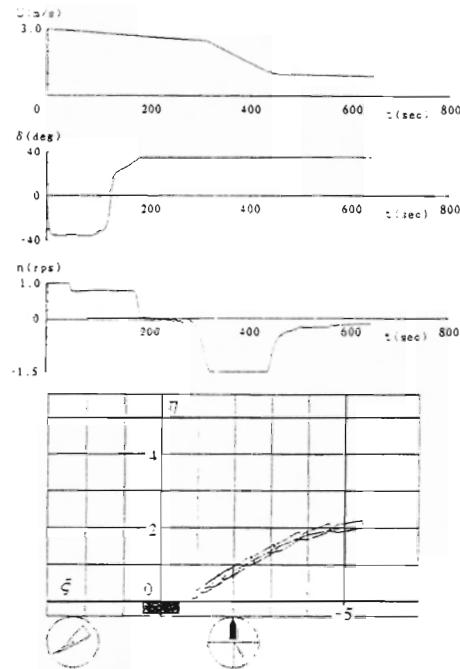


Fig. D1 Simulation of the case :  $(5L, 1L)$ ,  $\phi = -10(\text{deg})$  without regarding  $x$  and  $y$

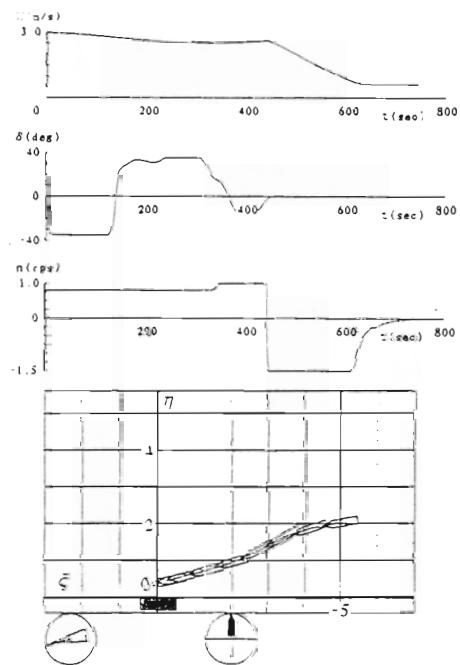


Fig. D2 Simulation of the case :  $(5L, 1L)$ ,  $\phi = -10(\text{deg})$  with regarding  $x$  and  $y$

力を得るように結合係数とオフセットを決めます。したがって、そのパターンからはずれるにしたがって、ネットワークは他のパターンの影響を受け、大きっぽい言い方をあえてすると「二つの参照パターンの操作をためらいながら繰り返す」ことになります。

したがって、これに対処するにはそのタイミングと操作量をパターンとの関係が線形になるように与えればよいわけですが、それではなんのためのニューラルネットワークかわかりません。むしろ、このままの方が人間の操作に近く、対雑音性がよいと思われます。ただ、操舵機や機関を高周波の操作から保護する目的なら単純にローパスフィルターを挿入すればよいと思います。ただし、カットオフ周波数の選定については留意が必要です。

2. 本文に書きましたようにその違いは単に座標系の違いで、大和ら<sup>7)</sup>は $x, y$ のみを使用しています。しかし、特に着棧直前において同じ $x, y$ であっても棧橋とのなす角によってその操作量は違うはずです。本来なら $y$ によって、その影響は入っているはずですが、 $x, y$ はその影響をさらに補強するものと考えています。参考までに $x, y$ を入れないケース(Fig. D1)と入れたケース(Fig. D2)の違いを示します。なお、実際の入力値はいずれも値が $0 \sim 1$ になるように適当に正規化して使用しています。
3. 教師データはパソコン上に構築した操船シミュレータを用い、画面上の航跡図を見ながら木寺が操船しました。このシミュレータは実時間と高速シミュレーションの切り替えが可能で、手動では実時間、シミュレーションでは高速で行いました。もちろん、船の操船については素人ですが、適当な指導と練習の後で行いました。そして、7つのパターンから適当なサンプル(通常は20~50秒毎、操作量が変化した前後では数秒毎)を行い合計171組の入力データとその出力データを教師データとして用いました。問題点としては専門の操船者より教師データを得てないことが多いでしょうか。
4. 実際には、ディファレンシャルGPS[D.1]などの衛星を利用した測距または、ECDIS(電子チャート)と呼ばれる沿岸の海図情報をもったレーダーを利用すれば充分な精度が得られるものと思われます。  
[D.1] 加瀬順一他：ディファレンシャルGPSとその応用、航海、第111号、pp.42-50、1992年3月。

#### [討論] (北海道大学水産学部) 烏野 慶一

1. 船の自動航行等に次々と新しい方式を試み、成果を挙げていることに敬意を表します。さて、この度の方式では人間の脳にとって代わる計

算機が時々刻々と何等かをもとに判断していることと思いますが、それらを知ることが出来るのでしょうか、御教示のほどお願い致します。

[回答]

1. ご討論ありがとうございます。

ニューロネットワークがもっとも理解されにくいのがこの点かと思います。ニューロネットワークの利点が「学習」や「連想」といった点であるとするとき欠点は「知識表現の手法をもたない」あるいは「知識の抽出が困難」な点であると言われています。したがって、明示的には知ることができません。しかし、例えば文字認識などでは一定の「学習」のうち、それぞれのニューロンがある機能を分担して認識するようになっていることが、結合係数の値を調べることによりわかることがあります。むしろ、本文中に書きましたように「知識が陽に表現できない」分野での利用価値があるわけで、その知識が分析できるなら、ニューロネットワークをわざわざ使う必要はないと思います。

[討論] (石川島播磨重工業(株)技術研究所)

溝口 純敏

- 着棧では操舵、プロペラ回転数を用いて制御しますが、これらは最大値の制限など、非線形性の強い制御制限を有しております。このような特性を持ったものでもニューラルネットワークを用いたシステムでうまく制限範囲内で制御されるのでしょうか。

[回答]

- ニューラルネットワークのもう一つの利点がこの点ではないでしょうか。制御対象や制御入力に強い非線形性があっても制御部としてのニューラルネットワークが内部に非線形性を持っているため、その表現が特別の機構を付加することなく「学習」により、自然にできます。ニューラルネットワークの非線形性が制御対象の非線形性を相殺するように機能することも知られています[D.2].

[D.2] 山下裕他：ニューラルネットワークによる学習・適応制御、計測と制御、第30巻、第4号、pp.302-308、1991年4月。