

# ニューラルネットワークによる自動着栈に関する研究<sup>\*1</sup>

## — 模型実験による検証 —

正会員 中田昌宏<sup>\*2</sup>, 正会員 長谷川和彦<sup>\*3</sup>

## A Study on Automatic Berthing Using Artificial Neural Network - Verification of Model Ship Berthing Experiments-

By Masahiro NAKATA (Member) and Kazuhiko HASEGAWA (Member)

Ship berthing is one of the most difficult ship operations. In the previous works, the artificial neural network (ANN) is verified to make it automatically. However, there are still many obstacles before it will be practically used. One of the problems is neither sea trial nor model ship experiment was done before. We have conducted model ship experiments based on ANN, and discuss for the availability in various conditions, especially for the method how to provide suitable teaching data. Combining model ship experiments and simulation, we have concluded that ANN can be practically applicable for automatic ship berthing. Secondary, we have discussed on the structure design of ANN for this purpose and propose a new ANN structure rationally.

**Keywords:** *Artificial Neural Network, Automatic berthing, Model experiment, GPS, Teaching data*

### 1. 緒言

船舶の運航において出入港は欠かすことのできない重要な要素である。しかしその操船は非常に複雑であり、多くの経験が必要とされている。現実には、大型船舶においては各港ごとに操船に熟練した水先案内人の搭乗が義務化されており、一方で小型船舶においても繰り返される出入港により熟練した船長によって操船されているのが現状である。現在、そのような熟練技能を保持している船長や水先案内人が高齢化等の問題により減少の一途を辿っており、この事が大きな問題になっている。そういった現状からも船舶の自動着栈技術や操船者支援の確立が重要になって来ている。

ニューラルネットワーク (Artificial Neural Network :ANN) は経験学習機能や自己組織化機能を有し、この問題の解決方法の一つとして期待されている。ANNによる自動着栈はyamato<sup>1)</sup>に始まり、その後も長谷川<sup>2)</sup>によって続けられている。その結果 ANN を使っ

た自動着栈はシミュレーション上での着栈に成功している。しかしながら実際に ANN の制御としては岡崎<sup>3)</sup>による船舶の幅寄せ操船制御や浦<sup>4)</sup>の潜水艇の制御があるだけである。よって ANNによる自動着栈実験が行われたことはなかった。

本研究では実際に模型船を用いて ANNによる自動着栈実験を行い、同時に実験の過程で問題となる数々の要因の検証を行った。最後には実験結果より発生した ANNの問題点の改善としてパラレルニューラルネットワーク<sup>5)</sup>の構築とその検証を行った。

### 2. 対象模型船とニューラルネットワーク

#### 2.1 対象模型船

今回使用した模型船の主要目を Table.1 に、座標系を Fig.1 に示す。今回使用する模型船の構成図を Fig.2 に示す。模型船は制御装置であるオンボードコンピュータに GPS、ジャイロなどのデータ受信装置、モーターや舵などの各種制御装置が接続されている。無線送信機からの信号より、マニュアル航行から自動航行の変更や模型船の航行データの測定など、各種自動制御を行う機能を有している。また、シミュレーション計算には MMG モデルを使用した。

\*1 平成15年5月23日関西造船協会春季講演会において講演。原稿受付平成15年6月10日

\*2 三菱重工業(株) (研究当時 大阪大学大学院工学研究科船舶海洋工学専攻)

\*3 大阪大学大学院工学研究科船舶海洋工学専攻

Table.1 Particulars of ship.

Ship type	Tanker
Length	3.00(M)
Breadth	0.48 (M)
Draft	0.20 (M)
Cb	0.8293




Fig.1 Coordinate system for ship dynamics.




Fig.2 Equipment for experiment.

## 2.2. ニューラルネットワーク

本研究にて使用する ANN を Fig.3 に表示する。入力パラメータは空間固定座標  $\xi$ 、 $\eta$ 、方位角  $\psi$ 、速度成分  $u$ 、 $v$ 、 $r$ 、仮想線との距離を表す補助座標  $d1$ 、 $d2$  である。出力パラメータは舵角  $\delta$ 、プロペラ回転数  $n$  である。

Input layer    Hidden layer    Output layer




Fig.3 Artificial neural network.

## 2.3. 教師データ

教師データは ANN の性質を決定する重要なデータである。今回、教師データの作成方法による ANN の応答の変化を検証するために二種類の教師データを作成した。Fig.4 は模型船を実際に着桟操船させた実験データであり、Fig.5 はシミュレーション上で着桟操船を行った教師データである。




Fig.4 Teaching data in experiment data.




Fig.5 Teaching data in simulation.

## 3. 自動着桟実験

### 3.1 実験内容並びに結果

自動着桟実験は Fig.6 示す大阪大学構内にある実験池において実施した。この実験池に着桟目標地点を原点とし、桟橋に対して垂直と平行な軸を有する空間固定座標を設定した。

また、本研究における着桟成功は模型船が次の着桟成功条件を満たしている時とする。

- ① 着桟成功条件は前進速度が 0m/s 以下である
- ② 船舶の重心位置が着桟目標地点の一船長以内である
- ③ 方位角が桟橋に平行に  $\pm 20^\circ$  以内であることとする。




Fig.6 Coordinate system for experiment.

次に今回の実験のために用意した ANN について述べる。ANN 教師データを学習させることによって、教師データ外の値について補完を行う。一般的に単純な問題であれば

ANNの教師データの学習は学習回数を多くすれば良くなるとされている。しかし、今回のような複雑な問題であり、実際に船舶の制御を行う場合には学習回数を多くするだけではなく、完全に教師データを学習しているかどうかの確認を行わなければならなかった。こういったことから今回はANNの学習回数を1000回とし、その後に着棧成功率による学習判定を行った。着棧成功率とは対象となるANNによって自動着棧操船を行った時に着棧成功条件を満たしている割合である。学習判定ではシミュレーション上で教師データと同じ全ての初期状態から着棧を行い、その時に着棧成功率で学習成功かどうかを判定している。今回、学習成功とは着棧成功率が100%の時として判定を行った。

また、過去に同様の実験が行われた事がないことからシミュレーション上における学習判定に対して実験への有効性ははっきりしていなかった。その為、それぞれの教師データを学習したANNに対して学習成功、学習失敗と判定されたものと合計四種類のANNを用意した。四種類のANNの内容をTable.2に示す。

Table.2 ANN for experiment.

Teaching data	Leaning result (Berthing rate)	Experiment result	Berthing rate
Experiment data	Success (100%)	Fig.7	93%
Experiment data	Failure (0%)	Fig.8	0%
Simulation	Success (100%)	Fig.9	80%
Simulation	Failure (50%)	Fig.10	42%




Fig.7 Result of experiment.




Fig.8 Result of experiment.




Fig.9 Result of experiment.




Fig.10 Result of experiment.

それぞれのANNによる模型船の航跡の一例を Fig.7 から Fig.10 に、着棧成功率を Table.2 に示す。Fig.7 と Fig.9 においてほとんどの軌跡で模型船は自動着棧を成功させている。よってANNによる模型船の自動着棧は可能であることが判った。そして Table.2 より着棧成功率はシミュレーション上の判定結果とほぼ同率である事が判明した。よってシミュレーションによる学習結果の判定は有効である事がといえる。また、学習成功していれば教師データの作成方法は実験、シミュレーションとどちらでも良いことが判明した。

### 3.2 実験考察

今回の実験結果より以上のことが判明した。

- 1) ANNによる模型船の自動着棧は可能である。
- 2) 着棧成功率の傾向はシミュレーション上の判定結果と同等であり、シミュレーションによる学習結果の判定は有効である。
- 3) 教師データ、学習判定にシミュレーションを使用して可能である。






Fig.11 Result of experiment.

#### 4. ANNの構造解析

教師データが実験データであり、学習成功しているANNによる実験結果にFig.11のように着棧に成功しているながらも着棧目標地点近郊で一旦プロペラを後進させ、また前進をするという現象がいくつか発生した。このような現象はこのANN以外では発生していなかった。よってこのANNを調査し、この原因を考えると共に今まであまり明らかにされて来なかったANNの入出力関係の調査を行った。




Fig.12 Phase analysis for teaching data and experimental result under error operations ANN.

#### 4.1 入出力の位相面解析

今回使用したANNはFig.2の8入力2出力型のフォワードモデルである。その入出力関係は複雑な多次元関数になっておるために、その入出力関係も非常に複雑である。本研究ではANNの入出力関係を調査するために、まず、プロペラ回転数を中心として入力と出力を一对一の関係で表した位相面解析を行った。これは教師データと実験結果をそれぞれ横軸に各入力パラメータとして、縦軸にプロペラ回転数としてグラフ化したものである。これによってプロペラ回転数に対する各入力パラメータの影響を調査した。つまりこれは、このグラフからプロペラ回転数の後進の際に教師データと実験データのグラフが一致していれば、その入力パラメータがプロペラ回転数の決定に対して影響は高く、教師データと実験データのグラフが一致していなければ、その入力パラメータの影響は低いということが判断できる。この位相面解析のグラフとFig.12に示す。この図より各入力パラメータはプロペラ後進時にψ、u、v、rは教師データと重なり、

ξ、η、d1、d2は教師データと離れた位置にある。その結果このANNではψ、u、v、rの影響が高いということが判明した。

#### 4.2 ANNの入出力相関関係

先の位相面解析とは別にANN自体の入出力関係についての検証を行った。これは先の位相面解析だけでは各入力パラメータ間でどのパラメータの影響が最も高いのかを判断できないからである。よってANNを構成している中間パラメータを元に入出力相関関係を次の計算式により比較する。

$$C_{ik} = \sum_j (W_{j,i} - b_i)(W_{k,j} - b_j)$$

この式はFig.2のi番目の入力とk番目の出力の相関関係を入力層から中間層、中間層から出力層までの「重み」の積として表現した。よってこの値が大きければそれは、入出力の相関関係が高いということである。この相関関係の解析結果をFig.13に表示する。Fig.13ではプロペラ回転数、舵角を同時に評価するために各出力に対して最大の値を使い正規化し絶対値で表示した。

Fig.13より、教師データが実験データであるANNにおいてプロペラ回転数の決定に影響が高いのはψ、u、d1、d2であった。同時に教師データが実験データの時にはプロペラ回転数、舵角ともに各入出力パラメータ間の相関関係がほぼ同じ傾向にあることがわかった。一方で教師データがシミュレーションデータのANNの解析結果もFig.13に表示する。このANNには先のような途中停止現象が起きていないことから両者の比較も行ってみたい。

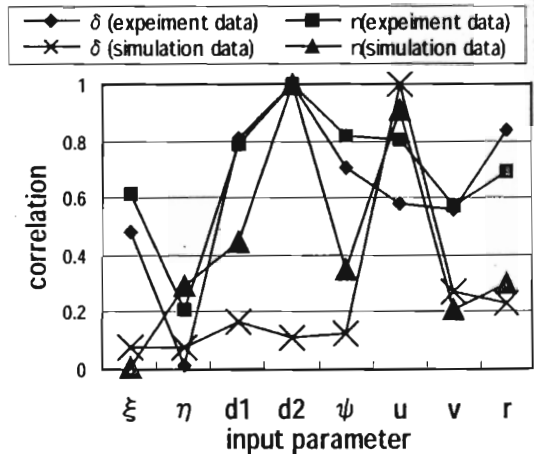


Fig.13 Correlation of inputs and outputs parameters.

このANNではプロペラ回転数の決定に影響が高いのはu、d2であることが判った。これは教師データが実験データの時のANNと比較して、ψ、d1の影響が低いということになった。このことに関して考えてみると、特にd1は着棧目標地点までに距離であるからプロペラ回転

数に対して影響が高くて低くても構わないが、 $\psi$ は同じ値を取っていてもその距離に対してプロペラ回転数が異なることから、プロペラ回転数の決定に対して影響が低いと考えられる。よって $\psi$ の影響の違いが大きな要因と考えられる。また、別に大きな特徴としてはプロペラ回転数、舵角に対する入力パラメータの傾向が異なっていることが上げられる。二つの ANN の比較をした結果、次のようなことが言える。

- 1) プロペラ回転数には方位角の影響が低い。
- 2) プロペラ回転数と舵角に影響を及ぼす入力パラメータの傾向は異なる

よって、ANN の入出力相関関係がプロペラ回転数と舵角で同じ傾向であり、方位角の影響が高いことが今回の途中停止を引き起こす原因と考えられる。

#### 4.3 まとめ

二種類の解析法を用い、ANN の構造解析を行った。その結果、今回の現象も主な原因がプロペラ回転数の決定に対する方位角の影響の高さであることが判明した。またこの現象を起していない ANN との比較を行うことによってプロペラ回転数と舵角の決定に影響がある入力パラメータは異なっていることが良いということが判明した。

### 5. パラレルニューラルネットワークの構築

先の解析結果は一見 ANN が同じ出力をしていますが、その内部構造は全く異なっていることが判明した。特にプロペラ回転数と舵角に対する入力パラメータの影響の違いが大きな問題であった。こうした現象の解決方法としてはプロペラ回転数、舵角ごとに ANN を作成するパラレルニューラルネットワークがある。この構成図を Fig.14 に示す。プロペラ回転数、舵角共に先の入出力関係の結果より特に途中停止を起していない教師データがシミュレーションの時の ANN を参考にして、それぞれに影響が高いパラメータを入力した。特に先程大きな問題になった方位角はプロペラ回転数には入力しないようにしている。次にパラレルニューラルネットワークの効果を確認するためにシミュレーション上で途中停止を行った地点の少し前の地点から着機を行い、パラレルニューラルネットワークの効果を確認した。その結果を Fig.15 に示す。この結果よりパラレルニューラルネットワークは途中停止を起すことなく着機を行っていることが確認できた。よってパラレルニューラルネットワークが有効であることが確認できた。

Input layer    Hidden layer    Output layer




Fig.14 Parallel neural network.

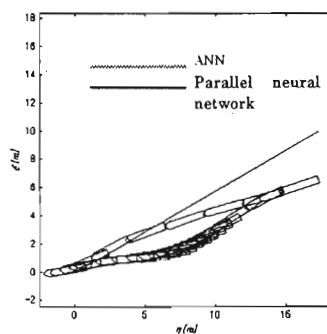


Fig.15 Comparison united and Parallel neural network

### 6. 結言

本研究の結論は以下の通りである。

- 1) 模型船による ANN を用いた自動着機は可能である。
- 2) 実験に対してはシミュレーションによる ANN の学習判定並びに教師データの作成は有効であることが判明した。
- 3) 実験により ANN のシステム上の問題点を分析し、それが各 ANN の出力を決定している入力パラメータの影響の違いであることが判明した。
- 4) 上記の問題点の改善として、パラレルニューラルネットワークを構築しその効果をシミュレーションで確認した。

### 謝 辞

今研究を行うにあたり、GPS などの実験機材を提供して頂きました日立造船(株)、日本 GPS ソリューションズ(株)には、厚く御礼申し上げます。

## 参考文献

- 1) H. Yamato *et al.*: Automatic Berthing by the Neural Controller, Proc. Of Ninth Ship Control Systems Symposium, vol. 3, pp.3.183-201, Bethesda, U.S.A., Sep., 1990
- 2) 長谷川和彦, 木寺啓治: 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棧システム, 関西造船協会誌, 220号, pp135-143, 1993
- 3) 岡崎忠胤, 正司公一, 水野直樹, 大津皓平: ANNによる最短時間操船に関する研究, 日本航海学会論文集, 97号, pp. 155-164, 1997
- 4) 藤井輝夫, 浦環, 黒田洋司, 能勢義昭: 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, 169号, pp477-486, 1991
- 5) Namkyun Im: Studies On Parallel Neural Controller And Motion Identification For Automatic Ship Berthing Using Neural Networks, 大阪大学博士論文, 2001

## 討 論

【討論】(神戸商船大学) 小林 英一

ニューラルネットワークを活用した制御法について模型実験による評価も試みられている取り組みに敬意を表します。

1. 当初のものとパラレル型とした場合それぞれについてニューラルネットワーク中間層のニューロン数の決め方についての考え方を教えてくださいでしょうか。
2. 実際の制御を行う場面では外乱が存在しますが、教師データを作成する時にこの外乱の影響について考察・検討されていればそれについてお教え下さい。またこの外乱時の制御性能を高めるための指針・見通しなどについてお教え下さい。

【回答】

ご討論ありがとうございます。

1. 現状では中間層の数の合理的決定法はまだ確立されておりません。ここでは、ニューラルネットワークの中間層の数は入力層と出力層の数に依存するものとして、中間層は入力層と出力層の積として決定しました。パラレルニューラルネットワークの場合にも上記の計算を行う予定でしたが、1出力であり中間層の数が少なすぎるとして、入力層の1.5倍の数として決定しました。

2. 今回、教師データ内に含まれる外乱の影響に関する検討は行っていません。著者の一人らによる過去の研究ではあるレベルまでの外乱下では制御可能ですが、外乱のレベルが大きくなると対応できていませんでした。よって外乱への対応につきましては、今後もさらに研究を進めていきます。

【討論】(鳥取大学) 秋元 博路

このニューラルネットワークへの入力データには、船外から見た座標系の位置データ等が含まれています。ネットワークがこのデータを利用するには、操船法と同時に、回転を含む座標変換も習得せねばならず、必要な学習量が増加すると思われます。入力する位置関連のデータは、船体固定座標系のものだけに限定した方が、学習効率が良いのではないのでしょうか？

【回答】

ご討論ありがとうございます。

発表時には十分に説明していませんでしたがニューラルネットワークの入出力関係を調査した結果より空間固定座標系の影響が小さいということも判明しております。ニューラルネットワークの再構築にはその結果も含めて行い、パラレルニューラルネットワークでは空間固定座標系は入力していません。