ニューラルネットワークを利用した船型初期計画 (第2報)

——中高速船の横切面積曲線計画ツールの構築——

正 員 松 村 竹 実* 正 員 浦 環**

Preliminary Planning of Ship Hull Form based on Artificial Neural Networks (2nd Report)

——Nonlinear Programming of Area Curve for High Speed Ships——

by Taketsune Matsumura, *Member* Tamaki Ura, *Member*

Summary

In this paper, the nonlinear programming system is proposed for preliminary planning of area curve for high speed ships. The system is composed of 4 neural networks; the Estimating Net, Descriptive Net, Integrating Net, and Optimizing Net.

The Optimizing Net proposes an area curve based on the design condition, i. e. target Froude number F_n , target Prismatic coefficient C_p , Length Breadth ratio L/B , and Breadth draft ratio B/d . Its output is connected to the inputs of other three forward model networks, which calculate resulted C_p , wave making resistance coefficient r_w , and teaching-data density parameter δ . The Optimizing Net is adjusted to minimize the evaluation function J , whose elements are the outputs of three forward model networks using the error-back propagation method. Finally, the Optimizing Net proposes the optimum area curve for the given design condition.

Since the definition of J includes the output of Descriptive Net, the resulted area curve is certificated that it is inside of the domain of teaching data which are adopted for generation of the forward model networks. The introduction of Descriptive net's output to the evaluation function is one of the important features of the proposed system.

The proposed optimizing system involves non-linear effects on design parameters and their cross-interaction, so that it could recommend an innovative idea for ship design.

It should be emphasized that the forward model networks were generated based on the tank test data of *Series60*. When the other data are available, it is possible to make the system to cover much wider variety of ship hull form.

1. は じ め に

1.1 中高速船の船型初期計画

造波抵抗の比率が高い中高速船の船型初期計画においては、主要目などの制約条件下で目的関数（造波抵抗）を最小にする横切面積曲線形状の探索が課題となる。

この様な問題には従来より変分法や影響関数法を利用し

た手法¹⁾の他、非線形計画法²⁾を活用した例³⁾⁴⁾がある。非線形計画法では目的関数や制約条件を比較的自由に設定することができ、体系的な最適化も可能である。但し解に到達するまで何回も目的関数を反復評価するため、抵抗と船型パラメータが陰な関係にあると Fig. 1 に示す様な2重ループの収束計算が必要となり、パワー CAE⁵⁾とならざるを得ない。むしろ初期計画では、船型から陽に抵抗推定を行う手法を用いたライト CAE⁶⁾が実用的である。

1.2 横切面積曲線の従来計画手法

多賀野⁶⁾は造波抵抗係数 r_w を主要目比と横切面積曲線の陽な関数として2次形式の回帰式で表し、回帰係数 H_{ij} を多数の水槽試験結果から決定している。回帰式を偏微分して影響関数を導けば、排水量の増減部位に関する変更指

* 三井造船(株)船舶・艦艇事業本部

** 東京大学生産技術研究所

Fig. 1 Nonlinear Programming for Hull Form Design

針も得られ、実用的な横切面積曲線計画システムを構築できるとしている。

しかし、この様な影響関数法では横切面積曲線の改良はできても体系的な最適化はできないという欠点がある。また、回帰推定式自体にも問題のあることが前報⁷⁾その他⁸⁾で指摘されている。

1.3 ニューラルネットワークの導入

この様なデータを基にした初期計画用の推定ツールとして、著者等は既にニューラルネットワーク⁹⁾を応用した回帰型推定システム⁷⁾¹⁰⁾を幾つか構築している。前報⁷⁾ではバルブレス中高速船を対象にフルード数 F_n が 0.19~0.33 の造波抵抗推定を行い、良好な結果を得た。本報では、バルブレス中高速船の横切面積曲線計画を取り上げ、ニューラルネットの特徴を活かした最適化システムを提案する。

階層型ニューラルネットワークは出力層における教示データとの誤差エネルギー E を入力層側に逆伝播できる。ネットの学習は、逆伝播の過程でニューロン間の結合荷重を最急降下法¹¹⁾に従って修正し、誤差エネルギーを最小化することにより行われる。

このような誤差逆伝播アルゴリズム⁹⁾は誤差エネルギー E を目的関数値 J に置きかえると、非線形計画法の最適化アルゴリズムに等価となる。従って目的関数をニューラルネットによるフォワードモデル群の出力で構成すれば、誤差逆伝播アルゴリズムを応用することにより、目的関数値 J の最小となる横切面積曲線形状を探索することが可能となる。

本報ではフォワードモデルとして、前報で構築した推定ネット⁷⁾と随伴ネット⁷⁾¹²⁾の他に積分ネットを用意する。

推定ネット (Estimating Net) は Series 60¹³⁾¹⁴⁾¹⁵⁾ の水槽試験結果を学習データとして構築されたものであり、抵抗を船型の陽な写像関数として表すネットである。入力フルード数と主要目比、及び横切面積曲線形状パラメータ

Fig. 2 Optimizing Scheme of Proposed System

であり、出力は造波抵抗係数 r_w である。

一方、随伴ネット (Descriptive Net) は推定ネットの入力パラメータ超空間における学習点の擬似的密度を表すネットであり、推定対象に対応する水槽試験データがどの程度充足しているかを 0~1 の指標 δ で示す。 δ が高ければ推定ネットによる r_w の推定精度も高いことが確認されている。

また、本報で構築する積分ネット (Integrating Net) は横切面積曲線形状から柱形係数 C_p を算出するもので、排水容積に関する等号制約条件の満足化に利用する。

目的関数 J は以上 3 つのフォワードモデル群の出力値から構成され、最適化に際して造波抵抗、学習点密度、及び柱形係数が考慮されることになる。 J の最小化はさらに調整ネットを導入することにより行われる。調整ネット (Optimizing Net) は設計条件 (主要目比・排水容積・計画速力) から、目的関数最小となる横切面積曲線形状を提示するネットであり、その出力先は Fig. 2 に示すように先述の 3 つのフォワードモデルの入力に連結させる。これより 4 つのネットワークは、全体として 1 つのジョルダンモデルネットワーク¹⁶⁾¹⁷⁾を構成するようになる。

最適化のプロセスは Fig. 2 に示すように、目的関数値を誤差逆伝播法に従ってフォワードモデル群の出力から入力に、さらに調整ネットへと逆伝播させることにより行われる。逆伝播の際には調整ネットの結合荷重のみ変化させて J を最小 (厳密には極小) にする。これにより調整ネットは、排水容積に関する等号制約条件をみだし、かつ既に学習したデータの範囲を極端に逸脱することなく、造波抵抗係数が最小になる横切面積曲線形状を出力するように調整される。

以上、推定ネット、随伴ネット、積分ネット、及び調整ネットの 4 つのニューラルネットワークをあわせて横切面積曲線初期計画システムとする。

2. 横切面積曲線初期計画システム

節1.3で述べた計画システムは、与えられた設計条件（主要目比・排水容積・計画速力）の下、水槽試験データが充足した領域内で抵抗が最小となる船型を探索するものである。そのシステム構成は、目的関数と3つのフォワードモデル（推定ネット・随伴ネット・積分ネット）、及び調整ネットから成り立つ。Fig.3に具体的なネットワークによる構造を示しておく。

2.1 目的関数の設定

まず、目的関数 J は下式(1)のように設定する。これより上述の課題は目的関数 J の最小化問題に帰着される。

$$J = \frac{1}{2} \{ (r_w)^2 + \alpha (C_p^* - C_p)^2 + \beta (1.0 - \delta)^2 \} \quad (1)$$

ここで α, β はペナルティ係数であり、それぞれ排水容積の計画値、及び水槽試験データの充実度に関係する。 α は排水容積に関する等号制約条件に関わるので、比較的大きな値を設定する必要がある。これに対し β は J の最小値探索を既学習領域に留めるための係数なので、比較的小さい値にする。 β に過大な値を設定すると最小値探索が推定ネット教示学習点のみに限定されてしまうからである。従って各ペナルティ係数には $\alpha \gg 1.0 \gg \beta$ の下で適当な値を設定し、 J の収束結果に対して $|C_p^* - C_p|$ をある値 err_1 以内に、 $|1.0 - \delta|$ を err_2 以内に収めるようにする。ここでは C_p について有効数字2桁の精度確保を、 δ については0.6以上を目安として err_1 を0.005に、 err_2 を0.4に設定することとする。

このような目的関数の設定自体は、要素がニューラルネットワーク群（推定ネット・積分ネット・随伴ネット）の出力で構成されている点を除けば、通常のペナルティ関数法²⁾における設定と類似する。但し、ネットを構成するニ

ューロンには飽和特性があるので、横切面積曲線形状に関する不等号制約条件 ($\min. < \eta_i < \max.$) が自動的に満足される利点がある。

2.2 フォワードモデルネットワーク

2.2.1 推定ネットと随伴ネット

r_w を出力する推定ネットと δ を出力する随伴ネットの詳細は前報に譲るが、両ネットとも Fig.4 に示す Series 60 の水槽試験結果 726 点の学習をもとに構築されている。

これらの入力パラメータは、どちらもフルード数 F_n と船長幅比 L/B 、幅喫水比 L/B の他、横切面積曲線形状に関する6つのパラメータ、すなわち $L_E/L, L_R/L$ 、及び η_1, η_2, η_3 、それに C_{PR} で構成される。つまり入力合計で9次元のパラメータ超空間を構成する。ここに L_E, L_R はそれぞれエントランス長さ、ラン長さであり、 η_1, η_2, η_3 はそれぞれ、エントランス部を船長方向に4等分した位置 ξ_i における $A(\xi_i)/A_M$ である。 $A(\xi_i)$ は位置 ξ_i における横断面積で A_M は中央横断面積である。また C_{PR} はラン

Fig. 4 r_w Curves of Series60

Fig. 3 Constitution of Neural Networks in Proposed System

部における横切面積曲線の積分値である。

各入力パラメータの領域は Table 1 に示すように設定し、それぞれ上下限値が 1.0 及び -1.0 になるように線型変換を施している。一方、推定ネットの出力値 r_w に関しては低 F_n から高 F_n に至るまで同等の推定精度を確保するため、Fig. 4 に太線で示す上限・下限の境界線を設定している。実際のネットの出力に関しては、境界値が 0.0 及び 1.0 となるように F_n 毎に線型変換が施されている。境界線は 3 階 2 次の B スプラインで構成される。

ネットワークの構造は他ネットも含めて全て 3 層構造とし、中間層のニューロン数は推定ネット で 6、随伴ネット で 9 とした。なお、採用するニューラルネットワークの数学モデルの概要は前報⁷⁾ に示す。

2.2.2 積分ネット

C_P を出力する積分ネットの入力は横切面積曲線形状に関するパラメータ、すなわち L_E/L , L_R/L , 及び η_1 , η_2 , η_3 , それに C_{PR} のみなので、6 次元のパラメータ超空間を構成する。

推定ネットや随伴ネット同様、入力パラメータの領域は Table 1 に示すように設定し、それぞれ上下限値が 1.0 及び -1.0 になるように線型変換を施しておく。また、出力値 C_P に関しても 0.55~0.85 をその範囲とし、実際のネットの出力は、その範囲が 0.0~1.0 となるように線型変換されている。

学習の教示データ作成は解析的に行う。すなわち、教示点として先述の入力 6 次元超空間を一様に分割する $6^6 = 46,656$ 点を採用し、次式 (2) に基づいて C_P を算出しておく。これより学習データの入出力の組が 46,656 組用意される。

$$C_P = 1 - (1 - C_{PR})L_R/L - (1 - C_{PE})L_E/L \quad (2)$$

ここに C_{PE} はエントランス部における横切面積曲線の積分値を示す。エントランス部における横切面積曲線は 4 階の B スプライン関数を用いて表現されるので⁷⁾、積分値

Table 1 Input Parameter Limits for Estimating Net, Descriptive Net and Integrating Net

η_1	0.238 ~ 0.704
η_2	0.570 ~ 0.922
η_3	0.878 ~ 0.989
C_{PR}	0.60 ~ 0.73
L_E/L	0.28 ~ 0.50
L_R/L	0.39 ~ 0.50
L/B	5.50 ~ 8.50
B/d	2.10 ~ 3.50
F_n	0.19 ~ 0.33

C_{PE} は B スプラインの積分公式¹⁸⁾ に基づけば η_1, η_2, η_3 から算出可能である。

以上の手続きに従って準備した学習データをもとに、中間層ニューロン数 5 の積分ネットに学習回数 $466,560K = 46,656 \text{ points} \times 10,000 \text{ steps}$ 回教示したときの収束結果を Fig. 5 に示す。標本相関係数は 0.9998 となっており、初期計画ということを考慮すれば、 C_P の演算精度は実用上問題ないことが解る。

積分演算機能をこの様な比較的小規模な積分ネットで実現しておけば、目的関数中の $(C_P^* - C_P)^2$ は、先述の誤差逆伝播アルゴリズムに従って調整ネットに逆伝播できる。これより C_P , r_w , 及び δ の扱いは最適化のプロセスにおいて等価となり、排水容積に関する等号制約条件の特異性も目的関数中の $(C_P^* - C_P)^2$ にかかるペナルティ係数 α の大きさのみに帰着される。

付録 A.1 に得られた積分ネットの結合荷重と閾値を示しておく。

2.3 調整ネット

2.3.1 ネットワークの入出力構造

調整ネットの目的は入力設計条件に対応した最適な船型を提示することにある。その入力は計画フルード数 F_n^* と計画柱形係数 C_P^* , 及び主要目比 L/B , B/d の 4 つである。つまり設計条件は 4 次元超空間中の 1 点として与えられる。

一方、出力は横切面積曲線形状に関する先述の 6 つのパラメータで、 $\eta_1, \eta_2, \eta_3, C_{PR}$, 及び $L_E/L, L_R/L$ である。Fig. 3 に示すように、調整ネットの出力は先述のフォワードモデル群の入力に連結させる。

他ネット同様、入力パラメータの領域は Table 2 に示すように設定し、それぞれ上下限値が 1.0 及び -1.0 にな

Fig. 5 Correlation bet. Network Output and Learning Data

るように線型変換を施しておく。また、出力値群に関しては Table 1 に示す領域をその範囲とし、実際のネットの出力はその範囲が 0.0～1.0 に収まるように線型変換されている。

2.3.2 目的関数値の最小化プロセス

J の最小化プロセスは、1 つに連結された推定ネット、積分ネット、随伴ネット、及び調整ネットに誤差逆伝播学習を施すことにより行われる。但し、結合荷重の更新は調整ネットのみに対して行い、他のネットは各出力層における誤差信号 Δz_i^N を入力側へ逆伝播するのみとする。誤差信号 Δz_i^N は各ネットの最終層における出力値を z_i^N として次式 (3) のように表される。

$$\Delta z_i^N = \frac{\partial J}{\partial z_i^N} = \begin{cases} r_w & (\text{推定ネット}) \\ \alpha(C_p - C_p^*) & (\text{積分ネット}) \\ \beta(\delta - 1.0) & (\text{随伴ネット}) \end{cases} \quad (3)$$

具体的な最小化プロセスは Fig. 6 に示すように標準化学習 (Standardizing Process) と最適化学習 (Optimizing Process) の 2 段階に分けて行う。

1. 入力 4 次元超空間中に散在する多数の設計条件群を用意し、入力空間全体に対して J が平均的に最小化されるように学習を施す。誤差信号は全条件群に関して加算した上で調整ネットに逆伝播させる。これより調整ネットは入力設計条件に対し、 C_p と δ の制約を満足する標準的な横切面積曲線形状を出力するようにな

る。この過程を標準化学習とする。

2. 個別の入力設計条件に対する J の最小値探索は調整ネットの再学習により行う。調整ネット結合荷重初期値は標準化学習で得られる結合荷重値とする。この過程を最適化学習とする。

標準化学習は調整ネットによる J の最小値探索の出発点を標準的な横切面積曲線形状に指定する役割を持つ。全入力超空間に関する標準化学習を一度施しておけば、個別の設計条件に対する最適化学習は、不自然な局所解に陥ることなく短時間で解に収束し、初期計画にも充分対応できる利点がある。

3. 横切面積曲線計画例

3.1 標準化学習

本論では調整ネットの標準化学習に、入力 4 次元超空間中に散在する $6^4=1,296$ 点を採用する。但し実際の設計条件においては C_p^* に対して F_n^* に上限値 F_{nmax} があるのが普通である。従って教示点を 4 次元空間中に一様に散在させると、調整ネットに一部無理な設計条件を学習させることになり非効率的である。

そこで本論では Fig. 7 に示すように、Series 60 の水槽試験結果に基づいて F_{nmax} に関する境界設定を設ける。す

Fig. 7 C_p and F_{nmax} in Series 60

Table 2 Input Parameter Limits for Optimizing Net

C_p^*	0.60 ~ 0.80
L/B	5.50 ~ 8.50
B/d	2.10 ~ 3.50
F_n^*	0.19 ~ 0.33

Fig. 6 Standardizing Process and Optimizing Process

なわち最小二乗法による線形近似関数 $F_{nmax}(C_P)$ を設定し、次式(4)の不等号境界条件の下で1,296 教示点を先述の4次元超空間中に散在させる。

$$F_n^* \leq F_{nmax}(C_P) = -0.467C_P + 0.611 \quad (4)$$

Table 3 に、これらの教示点群を基にした6つの異なるペナルティ係数組による標準化学習の結果を示す。調整ネットの中間層のニューロン数は5とし学習回数は12,960 $K=1,296 \text{ points} \times 10,000 \text{ steps}$ で、いずれも学習は収束している。表中の $|r_W|$, $|C_P^* - C_P|$, 及び $|1.0 - \delta|$ は各々1,296 教示学習点に関する誤差絶対値の平均を表す。

また Fig. 8 には1,256 の教示点に関する β と δ の平均及び分散との関係を示しておく。ここに α は10.0とし、 δ は標準化学習で構築された調整ネットのプレイバック出力座標に基づく。これより β がある値以下になると入力設計条件によっては随伴ネットの出力が極端に低くなる解が生じることが解る。

随伴ネットは入力点が推定ネットの教示点から一定以上離れると急激に小さな値を示すステップ応答的な出力特性を有する⁷⁾。従って目的関数 J に出力値 δ の軽いペナルティを課しておけば既学習領域から著しく外れた場合にのみペナルティが強く作用し、 J の最小値探索領域を限定することが可能となる。但し β が過小だと J の最小値探索が δ の極端に低い未学習領域に及んでしまう。

ここでは以上の考察から $\bar{\delta} > 0.6$ を探索領域の適切な境

Table 3 Results of Standardizing Process

α	β	$ r_W $	$ C_P^* - C_P $	$ 1.0 - \delta $
20.0	0.100	0.101	0.00229	0.220
10.0	0.100	0.101	0.00406	0.221
10.0	0.050	0.092	0.00493	0.288
10.0	0.025	0.089	0.00451	0.340
10.0	0.010	0.071	0.00367	0.658
10.0	0.000	0.067	0.00286	0.880

Fig. 8 Penalty Coef. β and Descriptive Net's output δ

Table 4 Optimized Area Curve Data for 8 Design Cases

case No.	1	2	3	4	5	6	7	8
L/B	7.00		6.50				7.00	
B/d	2.75		3.00				3.00	
C_P^*	0.60		0.65				0.70	
F_n^*	0.300	0.200	0.300	0.300	0.200	0.200	0.270	0.200
α	10	10	10	10	10	10	10	10
β	0.025	0.025	0.100	0.025	0.010	0.025	0.100	0.100
η_1	0.238	0.238	0.238	0.238	0.238	0.238	0.238	0.353
η_2	0.570	0.570	0.600	0.679	0.669	0.570	0.727	0.814
η_3	0.931	0.938	0.898	0.941	0.954	0.909	0.945	0.958
L_E/L	0.500	0.470	0.500	0.500	0.437	0.471	0.414	0.380
L_R/L	0.490	0.500	0.497	0.472	0.500	0.500	0.457	0.488
C_{PE}	0.564	0.566	0.561	0.589	0.591	0.558	0.600	0.658
C_{PR}	0.622	0.603	0.730	0.687	0.654	0.720	0.707	0.649
C_P	0.597	0.598	0.646	0.650	0.648	0.652	0.701	0.699
δ	0.805	0.781	0.827	0.642	0.604	0.882	0.618	0.692
$r_W \times 10^3$	5.545	0.284	7.992	6.997	0.309	0.437	3.050	0.494

界と見做し, $(\alpha, \beta) = (10.0, 0.025)$ ペナルティ係数として採用する。付録 A.1 に同ペナルティ係数に基づく標準化学習により得られた調整ネットの結合荷重と閾値を示しておく。

3.2 最適化学習

次に節 3.1 で得られた調整ネットの結合荷重を初期値として, Table 4 に示す 8 つの設計条件に対する最適化学習を実施する。最適化学習におけるペナルティ係数は標準化学習と同じ組合わせとする。但し設計条件に対応する Series 60 のデータが少ない場合には δ は極端に低くなり得る。この様な場合は β を適当に上げて最適化学習を行い J の最小値探索領域を適切に設定する。調整ネットには標準化学習が施されている上, 設計条件も 1 ケースのみなので最適化学習の計算自体は容易に収束する。

J の最小値探索結果を設計条件とともに Table 4 に示

Fig. 9 Optimized Area Curves for Case No. 1 & 2

Fig. 10 r_w and δ Curves for Case No. 1 & 2

す。再学習回数は何れも 300 K である。

case 1~2 は $C_P = 0.6$ という瘦せ型の船型を対象としているため横切面積曲線の自由度はかなり限定されてしまう。従って J の最小値探索領域は随伴ネットの出力値 δ に制限される他, C_P^* に関する制約条件にも強く制限される。最適化学習により得られた横切面積曲線形状を Fig. 9 に, 造波抵抗曲線 (推定ネット出力) と随伴ネット出力曲線を Fig. 10 に示す。 F_n^* が低速域になると若干エンタランスが短くなり浮心位置が前方に移動している。この傾向は Series 60 の一部の試験結果にも明確に現れており, 推定ネットに汎化されたその傾向が調整ネットによって引き出されていることが解る。

case 3~6 は $C_P = 0.65$ の船型を対象としているため, 横切面積曲線の自由度は比較的大きい。同一 C_P^* の等号制約条件下でも様々な L_E や L_R 及び C_{PE} や C_{PR} の組み合わせが可能になるからである。case 3 と 4 は $F_n^* = 0.3$ の高速域を, case 5 と 6 は $F_n^* = 0.2$ の低速域をそれぞれ設計条件としている。同一設計条件でも β を意図的に変化させて, 最適化学習の収束結果を比較している。

得られた横切面積曲線形状を Fig. 11 及び Fig. 12 に,

Fig. 11 Optimized Area Curves for Case No. 3 & 4

Fig. 12 Optimized Area Curves for Case No. 5 & 6

Fig. 13 r_w and δ Curves for Case No. 3~6

Fig. 14 Optimized Area Curves for Case No. 7 & 8

造波抵抗曲線（推定ネット出力）と随伴ネット出力曲線を Fig. 13 に示す。全体的に F_n^* が低くなるとエンタランスが短くなり、浮心位置が前方に移動している点は先述の通りであるが、同一 F_n^* でも δ が 0.6 前後に低くなると C_{PE} が増加し、 C_{PR} が小さくなっている。形状の自由度が大きいことと相俟って、 J の最小値探索領域が相対的に広がり、 β によって最終的な横切面積曲線形状が異なってくるのが解る。

case 7~8 は $C_P=0.7$ の船型を対象としているが、Series 60 のデータでは高速域がやや不足気味の領域である。このため β は 0.1 に増加させた上で最適化学習を行っている。最適化学習により得られた横切面積曲線形状を Fig. 14 に、造波抵抗曲線（推定ネット出力）と随伴ネット出力曲線を Fig. 15 に示す。 F_n^* が低速域になるとエンタランスが短くなり浮心位置が前方に移動しているのは先述の通りである。

Fig. 15 r_w and δ Curves for Case No. 7 & 8

最終的な β 値は初期計画時の方針等に応じて上下に変更させる。即ち、推定精度を重視して水槽試験実績の範囲内で設計をすますのか、それとも開発目標等を定めるのかに応じて β を上下させ、 J の最小値探索領域を設定する。但し得られる横切面積曲線形状の δ が 0.4 未満の場合は本質的に水槽試験データが不足している領域であり、 β の値を大きくするか、或いは別なアプローチを採用する必要がある。

4. 結 論

前報が推定という順問題を扱ったのに対し、本報は計画・最適化という逆問題を扱っている。

前報で構築した推定ネットと随伴ネットに加え、本報では積分ネットを構築して横切面積曲線計画に必要なフォワードモデル群を完成させた。これらのネットによる推定計算自体は重い数値計算等を必要とせず、初期設計におけるライト CAE として理想的である。

さらにニューラルネットワークの誤差逆伝播学習法が本質的に非線形計画法と等価であることに着目し、調整ネットを導入して横切面積曲線の計画手法を考案した。

調整ネットは言わば上述のフォワードモデル群の逆写像で、2段階の学習プロセス、即ち標準化学習と最適化学習を通して目的関数が最小となる横切面積曲線形状を出力するようになる。

目的関数は、造波抵抗係数 r_w 、柱形係数誤差 $C_P^* - C_P$ 、及び随伴ネット出力値の関数 $1 - \delta$ 、以上3つのペナルティ係数を介したエネルギー和で設定されているので、調整ネットは、排水容積に関する等号制約条件をみだし、かつ既に学習したデータの範囲を極端に逸脱することなく、造波抵抗係数が最小になる横切面積曲線形状を出力するよう

になる。

粘性抵抗や水線面積係数の制約などに代表される他の要素も、対応するフォワードモデルさえ構築できれば、フォワードモデルを増やした同様の手法により、総合的な最適化を計ることができる。

目的関数に随伴ネットのペナルティを課している点は本手法の特徴の一つで、信頼性の確保に大きな役割を果たしている。これはニューラルネットワークを用いる場合、入力超空間を埋め尽くせる程に十分な教示データを準備することは現実には不可能なため、実際にはどうしても未学習領域が存在してしまう。従って原理的には非線型計画法に応用できるとしても、随伴ネット出力のペナルティが無ければ、収束解が未学習領域に陥ってしまう可能性があり、信頼性を確保できないからである。

なお、3節以降で取り上げた例は Series 60 のデータのみに基づく補間超空間内での最小値探索である。従って3.2節で得られた横切面積曲線解は、あくまで Series 60 船型のデータのみに基づくものである。

各造船所に貯えられている多様で豊富な実用船型のデータを基に、推定ネット、随伴ネット、及び積分ネットのフォワードモデル群を再構築し、調整ネットを導入すれば、そのデータの範囲で実用的に満足できる最適横切面積曲線解が得られる。

参 考 文 献

- 1) 例えば、丸尾孟、山越康行：有限喫水を持つ極小造波抵抗船型の計算，日本造船学会論文集，Vol. 130 (1971)，pp. 31-40
- 2) 鈴木和夫、小柴幸男：船型計画法と線図生成，日本造船学会，推進性能研究委員会第5回シンポジウム—船体まわりの流れと船型開発に関するシンポジウム— (1993)，pp. 163-201
- 3) 鈴木和夫、丸尾孟、尾崎陽一：非線型計画法による船型設計の基礎的研究 (第5報)—低速造波理論に基づく極小造波抵抗問題—日本造船学会論文集，Vol. 154 (1983)，pp. 1-8
- 4) (社団法人) 日本造船研究協会：造船研究，Vol. 29，No. 1 (1997)，p. 37
- 5) 栗山利彦：車両最短開発の戦略ツールパワー CAE とライト CAE，—CAE による自動車のコストダウンを目指して—，自動車技術会シンポジウム，No. 9512 (1995)，pp. 4-10
- 6) 多賀野寛：統計解析による実用船型の造波抵抗推定法に関する研究，三菱重工技報，Vol. 11，No. 1 (1974)，pp. 111-121
- 7) 松村竹実、浦環：ニューラルネットワークを利用した船型初期計画 (第1報)—中高速船の造波抵抗推定ツールの構築—，日本造船学会論文集，Vol. 183 (1998)，pp. 91-100
- 8) 岩瀬俊一、多賀野寛：多賀野の方法における船体主要目と船体抵抗の関係について，日本造船技術センター技報，第11号 (1983)，pp. 39-46
- 9) 例えば、石川真澄：コネクションニズムと学習，認知

科学の発展，4 (1991)，pp. 51-77

- 10) 松村竹実、浦環：ニューラルネットワークを利用した中高速艇の速力性能初期推定ツールの構築，日本造船学会論文集，Vol. 181 (1997)，pp. 221-232
- 11) Press, W. H., Flannery, B. P., Teukolsky, S. A., and Vetterling, W. T.: Numerical Recipes in C, 技術評論社, (1992), pp. 307-312
- 12) 浦環、石井和男：ニューラルネット形成時の学習領域の記憶と知識獲得，日本造船学会論文集，Vol. 171 (1992)，pp. 587-593
- 13) Todd, F. H.: Some Further Experiments on Single Screw Merchant Ship Forms-Series 60, Trans. SNAME, Vol. 61 (1953)，pp. 516-589
- 14) Todd, F. H. and Pien, P. C.: Series 60-The Effect upon Resistance and Power of Variation in LCB Position, Trans. SNAME, Vol. 64 (1956)，pp. 4-68
- 15) Todd, F. H. and Pien, P. C.: Series 60-The Effect upon Resistance and Power of Variation in Ship Propotions, Trans. SNAME, Vol. 65 (1957)，pp. 445-589
- 16) Jordan, M. I. and Rumelhart D. E.: Forward Models -Supervised Learning with a Distal Teacher-, Cognitive Science, 16 (1992) pp. 307-354
- 17) 藤井輝男、浦環：ニューラルネットによる潜水艇の運動制御—水平航行の制御への適用—，日本造船学会論文集，Vol. 166 (1989)，pp. 503-511
- 18) 桜井明、菅野敬祐、吉村和美、高山文雄：C によるスプライン関数、—データ解析・CG・微分方程式—東京電気大学出版局, (1993)，pp. 131-155

付 録

A.1 結合荷重の表

積分ネットに関する入力パラメータの線型変換を施すベクトルを式(5)に示す。これらの数値は Table 1 に対応している。また、記号等は前報⁷⁾に従っている。

$$u_i^1 = w_{ij}^0 I_j + h_i^1$$

$$= \begin{bmatrix} 4.292 & \eta_1 \\ 5.682 & \eta_2 \\ 17.857 & \eta_3 \\ 15.385 & C_{PR} \\ 9.091 & L_E/L \\ 18.182 & L_R/L \end{bmatrix} + \begin{bmatrix} -2.021 \\ -4.239 \\ -16.679 \\ -10.231 \\ -3.545 \\ -8.091 \end{bmatrix} \quad (5)$$

積分ネットの結合荷重行列と閾値ベクトルを式(6)～(8)に、同じく調整ネットのものを式(9)～(12)に示す。

$$w_{ij}^1 = \begin{bmatrix} 0.399 & 0.195 & 0.084 \\ -0.106 & -0.054 & -0.027 \\ -5.93 & -0.284 & -0.115 \\ -0.690 & 0.333 & 0.136 \\ -0.268 & -0.132 & -0.065 \end{bmatrix}$$

$$\begin{bmatrix} 0.772 & -0.420 & -0.020 \\ 0.279 & -1.228 & -0.466 \\ -0.202 & 0.762 & 0.124 \\ 0.189 & -0.034 & -0.437 \\ -0.824 & 0.300 & 0.509 \end{bmatrix} \quad (6)$$

$$w_{ij}^2 = [4.145 \ 1.334 \ -4.682 \ 2.621 \ -9.274] \quad (7)$$

$$h_i^2 = \begin{bmatrix} -2.844 \\ -2.095 \\ -2.906 \\ -2.351 \\ -4.407 \end{bmatrix}, \quad h_i^3 = 0.0735 \quad (8)$$

$$w_{ij}^1 = \begin{bmatrix} -6.034 & 0.029 & 0.097 & -0.137 \\ -4.638 & 0.025 & 0.016 & -0.032 \\ -5.304 & -0.056 & 0.000 & -0.700 \\ -9.838 & -0.019 & -0.004 & 0.100 \\ -4.907 & -0.000 & -0.084 & 0.948 \end{bmatrix} \quad (9)$$

$$w_{ij}^2 = \begin{bmatrix} -2.022 & -3.879 & -2.047 & -3.835 & -2.176 \\ -2.176 & -2.158 & -1.378 & -0.266 & -1.244 \\ 0.625 & -0.300 & -0.584 & -1.445 & -0.766 \\ -2.213 & 0.182 & -1.690 & -2.579 & -1.909 \\ 2.928 & 3.449 & -2.242 & 4.252 & 3.938 \\ 3.872 & 2.022 & -5.117 & 4.591 & 1.503 \end{bmatrix}$$

(10)

$$h_i^2 = \begin{bmatrix} -4.163 \\ 1.224 \\ -3.410 \\ 6.296 \\ -3.152 \end{bmatrix} \quad (11)$$

$$h_i^3 = \begin{bmatrix} 1.183 \\ 1.715 \\ 1.771 \\ 4.026 \\ -6.914 \\ -5.930 \end{bmatrix} \quad (12)$$