

# 선박의 성능 요소 추정을 위한 신경망의 실용화 연구

김현철\* · 박형길\*\*

\*울산과학기술대학교 기계공학부

\*\*삼성중공업 중앙연구소 조선해양연구소

## Practical Application of Neural Networks for Prediction of Ship's Performance Factors

Hyun-Cheol Kim\* and Hyoung-Gil Park\*\*

\*School of Mechanical Engineering, Ulsan College, Ulsan, Korea

\*\*Samsung Ship Model Basin, Central Research Institute, Samsung Heavy Industries Co., Ltd., Daejeon, Korea

**KEY WORDS:** Neural Networks 신경망, Performance factors 성능요소, Resistance factors 저항요소, Self-propulsion factors 자항요소

**ABSTRACT:** In the initial ship design stage, performance predictions are generally carried out before and after the hull form design. The former is based on the main dimensions and power information, and the latter is based on the geometry of the hull form and propeller. This paper deals with the practical application of neural networks for the prediction of a ship's performance factors before and after the hull form design. For this, the hull form parameters that affect the performance are studied, and an optimal neural network structure based on the SSMB database is constructed. By comparing the results predicted by neural networks and the model test results, we confirmed that neural networks can be applied to practically evaluate the performance in the initial ship design stage.

### 1. 서 론

최근 국내외 연구소나 기관에서는 자체 모델 성능 시험 결과에 대한 데이터베이스를 구축하고, 이를 기반으로 초기 설계 단계에서 선박의 성능을 예측하고 평가하는 응용 프로그램을 독자적으로 개발하여, 성능 분석 방법의 일관된 기준을 확립하고자 하는 노력이 이루어져 왔다. 이와 더불어 컴퓨터의 진보는 수치 계산 기법 연구에 활력을 주어 저항/자항성능, 프로펠러 평면상에서의 공칭 반류, 프로펠러 캐비테이션 그리고 최근에는 조종성능 분석까지 그 적용영역이 확대되었으며, 그 정도(Precision)는 정성적인 우열 비교와 함께, 일부 분야에서는 정량적인 값을 추정하는 수준으로 발전해 오고 있다. 특히, 최근 선종의 다양화, 고속화 그리고 대마력화 등의 요구에 따라 성능 예측 및 평가가 대단히 중요한 화제로 부각되고 있으며, 신속하고 정확한 성능해석으로 발생 가능한 문제를 사전에 대처 가능한 능력을 보유하는 것이 치열한 수주 상황에서 기술적인 우위를 점하는 수단이 될 것이다.

선주 요구 조건으로부터 향후 예견되는 선박의 유체 동역학

적 특성을 예측하여 성능을 추정하는 방법으로는 일반적으로 전산유체역학(CFD, Computational fluid dynamics)에 의한 성능 추정 방법과 기존에 개발된 실적선 및 추진기 설계결과를 바탕으로 한 통계적 추정 방법으로 구분할 수 있다. 전산유체역학에 의한 성능 추정 방법은 선박 주위에서 생성되고 소멸되는 일련의 유동 현상을 수치 계산에 의해 미리 시뮬레이션해 볼 수 있는 장점이 있지만, 정확한 유동 해석을 위해서는 계산 시간이 오래 걸리고, 일부는 해결되지 않은 자연 현상에 대한 모델링 및 해석에 한계를 가진다. 반면, 통계적 성능 추정 방법은 이미 수행된 모형시험 데이터를 통계적으로 해석하여 입출력 설계 변수들 간의 상호관계를 일정한 유형의 경험식 혹은 비선형 모델링 방법으로 표현하여 설계에 적용하는 방법으로, 방대한 양의 모델 시험 결과를 보유한 연구소 및 기관에서 널리 활용되고 있다. 이 방법은 적은 수의 설계 변수로 전역적 성능(Global performance)을 신속하게 파악할 수 있는 장점이 있는 반면, 국부적인 유동 현상을 정량적으로 파악하기 어렵고, 통계적 데이터로 사용된 모형시험 범위 내에서만 신뢰성 있는 결과를 제공한다는 단점이 있다.

Received 15 November 2014, revised 26 February 2015, accepted 16 April 2015

Corresponding author Hyun-Cheol Kim: +82-052-279-3103, hckim@uc.ac.kr

© 2015, The Korean Society of Ocean Engineers

통계적 추정 방법으로는 일반적으로 회귀식이 사용되는데, 입출력 데이터의 특성이 비선형인 경우에는 충분히 표현하기 어렵다.

특히, 초기 선박 설계 단계에서 선형 요소와 제 성능과의 관계는 대부분 비선형이므로, 이를 표현하기 위한 새로운 개념의 모델링 방법이 연구되었다. 대표적인 비선형 모델링 방법으로는 퍼지 모델링과 신경망을 들 수 있으며, 다양한 응용 분야에 수행되어 왔지만, 선박 설계 분야에서는 국내에서 소수 연구들만이 수행되었다.

국내에서 Kim and Lee(1992)가 퍼지 모델링과 선박의 형상 파라미터들을 이용한 선형 생성 방법을 소개한 이후, 선박의 초기 설계의 다양한 분야에 퍼지 모델링과 신경망이 적용되었다 (Kim et al., 1995; Kim et al., 2002, Shin et al., 2002; Shin et al., 2012). 특히, 선박의 주요 치수와 선형 계수간의 모델링을 보다 효율적으로 정의하기 위해 퍼지 모델링과 신경망의 장점들을 결합한 선박 설계용 뉴로 퍼지 시스템을 개발하려는 연구가 시도되었다(Kim and Kim, 1998; Kim et al., 1998a; Kim et al., 1998b; Kim et al., 1997). 그러나 이들 논문들은 비선형 데이터의 모델링을 선박 설계에 적용하기 위한 새로운 시도로서의 의미는 있으나, 실질적 자료가 부족하여 실용 가능성을 충분히 확인하기에는 한계를 가지고 있었다. 이후 조선소에서 실제 적용 가능성을 확인하는 연구가 수행되었는데, 그 예로 Kanai(2000)은 선박의 마려 추정과 선형 최적화에 신경망을 적용함으로써 실제 설계 작업 시 적용 가능성을 검토하였다.

본 연구는 SSMB (Samsung ship model basin)에서 축적해 온 많은 모형시험 결과들을 체계적으로 정리하여, 초기 설계 단계에서 선박의 저항 및 자항 요소 추정을 위한 신경망을 모델링하여, 그 결과를 분석하였다. 선형 설계 파라미터의 영향도 분석을 위해 신경망은 선형 설계 이전과 이후의 두가지 방법으로 모델링되었으며, 선형 설계 이전 즉, 선형이 없는 경우에는 Holtrop and Mennen(1982)에서와 동일한 설계 입력 변수들을 적용하였고, 선형 설계 이후에는 선형 및 추진기의 국부적 형상 파라미터들을 설계 입력 변수들로서 추가하여 모델링하였다. 그리고 두가지 방법에 의한 추론 결과를 SSMB 자체 보정계수를 적용하여 현재 사용하고 있는 개선된 Holtrop and Mennen 방법과 함께 비교·분석함으로써 실제 설계 단계에서의 적용 가능성을 검토하였다.

## 2. 신경망의 구성 및 학습 방법

신경망은 뇌에 존재하는 생물학적 신경세포와 그것들을 연결하는 연결 관계를 단순화시켜 수학적으로 모델링하여 뇌가 나타내는 지능적인 형태를 구현하고자 하는 비선형 모델링 방법이다. 수학적 신경망의 기본 구성 요소는 처리요소(Process element)를 나타내는 뉴런(Neuron)과 뉴런을 연결하는 커넥션(Connection)으로 구성되며, 뉴런 연결 방법에 따라 다양한 형태의 신경망이 구성될 수 있다. 본 연구에서는 상용 소프트웨어인 Neuralworks professional II/plus (Neuralware, 2001)의 오류 역전파(Error back-propagation) 알고리즘을 사용하였으며,

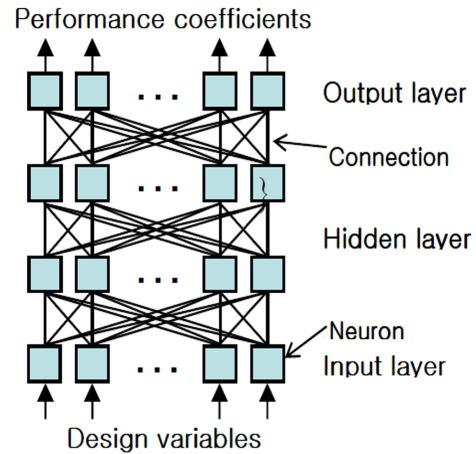


Fig. 1 Concept of multi-layer neural networks

연결 가중치의 수렴률(Rate of convergence)를 강화한 EDBD (Extended delta-bar-delta) 학습 방법(Minai and William, 1990)을 적용하였다. 오류 역전파 알고리즘은 1985년 Rumelhart에 의해 소개된 방법(Rummelhart et al., 1985)으로, 수평으로 늘어선 한 무리의 뉴런의 모임을 층(Layer)이라 하여, 같은 층 내의 뉴런은 기능적으로 같은 작업을 수행하며, 동시 동작과 병렬 동작의 기본 단위가 된다. 각 층의 뉴런과 연결은 각각의 전이함수(Transfer function)와 가중치(Weight)를 표현하고 있는데, 입출력 패턴의 상관관계가 밀접하게 되도록 이들 값을 조절하는 과정을 학습(Learning)이라 한다.

오류 역전파 알고리즘은 신경회로망의 출력패턴(Output pattern)과 목적패턴(Object pattern)과의 오차(Error)로부터 델타(Delta)를 구한 후, 그 결과를 뉴런을 구성하는 각 층(Layer)으로 역전파시켜 연결의 가중치를 조절하는 방법으로, 일반적으로 공학의 제어나 추론 분야에 널리 사용되고 있다. Fig. 1은 오류 역전파 신경망의 개념적 구성도를 나타내며, 입력을 받아들이는 입력층(Input layer)과 외부로 출력하는 출력층(Output layer)으로 구성되며, 필요시 입력과 출력사이에 은닉층(Hidden layer)을 두고 있다. 입력층의 뉴런은 설계 변수(Design variable)이며, 설계 목적에 따라 주요치수와 같은 전역적 설계 변수와 선미 선형 정보와 같은 국부적 설계 변수가 함께 사용될 수 있다. 출력층의 뉴런은 구하고자 하는 성능 계수(Performance coefficients)로 표현될 수 있으며, Fig. 1의 신경망은 저항 및 자항 추정을 위한 독립적인 유닛(Unit) 모델로서 사용된다. EDBD 학습 방법은 Rummelhart가 소개한 표준 델타 학습 방법(Standard delta rule)의 학습능력을 향상시킨 방법으로, 각 연결 가중치의 학습률(Learning rate)과 각 뉴런의 전이함수 값의 변화율 즉, 모멘텀(Momentum)을 독립적으로 학습시킨다. 이 방법은 학습시간을 단축하고, 연결치 조정에서 초기 수렴하는 위험을 방지하는 장점을 가진다.

## 3. 설계 입출력 변수와 신경망의 최적 구조 결정

신경망의 국부적인 성능은 학습을 통한 뉴런의 전이함수 유

**Table 1** Input-output design variables for the modeling of neural networks before the hull form design

Item	Parameter	Description	Remarks	
Input design variable	1	Type of Ship	0: Tanker 1: Container ship 2: LNGC	Hull factors
	2	<i>LBP</i>	Length between perpendiculars [m]	
	3	<i>B</i>	Breadth [m]	
	4	<i>T</i>	Design draft [m]	
	5	<i>C<sub>b</sub></i>	Block coefficient	
	6	<i>LCB</i>	Longitudinal center of buoyancy [m]	
	7	<i>NCR</i>	Normal continuous rating [kW]	Power related factors
	8	<i>RPM</i>	Revolutions per minute [rpm]	
	9	<i>F<sub>n</sub></i>	Froude number	
	10	No. of Prop.	Number of propeller	Propeller factors
	11	No. of Blade	Number of propeller blade	
	12	Dia. of Prop.	Diameter of Propeller [m]	
Output design variable	1	T. Proj. A	Transverse projection area [m <sup>2</sup> ]	Hull factors
	2	<i>WSA</i>	Wetted surface area [m <sup>2</sup> ]	Resistance factors
	3	<i>C<sub>r</sub></i>	Residuary resistance coefficient	
	4	<i>W<sub>tm</sub></i>	Wake fraction coefficient in the model scale	Self-propulsion factors
	5	<i>W<sub>ts</sub></i>	Wake fraction coefficient in the full scale	
	6	<i>t</i>	Thrust deduction coefficient	
	7	<i>E<sub>taR</sub></i>	Relative rotative efficiency	
	8	<i>E<sub>taO</sub></i>	Propeller efficiency in open water	

형과 연결 가중치에 의해 결정되지만, 전역적 성능은 구조적 요소 즉, 은닉층의 개수 및 은닉층 뉴런 개수, 학습 방법, 입출력 변수의 개수 등에 의해 결정된다. 이들 구조적 요소들은 일반적으로 모델링하고자 하는 입출력 데이터의 유형과 특성에 따라 상관관계(Correlation)를 고려하여 최적의 신경망 구조를 결정한다. 또한, 신경망의 학습에 사용되는 데이터의 개수는 모델링의 정도(Precision)뿐만 아니라, 학습 후 신경망의 추정에 크게 영향을 미친다. 여기서 데이터란 모델링에 사용될 입출력 변수들을 나타내며, 선종, 속도, 주요치수, 선형 및 추진기 형상 계수, 저항 및 자항 요소 등이 이에 해당한다. 학습할 데이터가 적고 입출력 변수의 개수가 많은 경우 입출력의 관계를 충분히 반영하여 모델링을 하더라도 전체적인 데이터의 유형을 파악할 정보가 충분치 않기 때문에 신경 회로망의 시스템이 불안정하여 추정 정도에 대한 신뢰도가 떨어질 수 있다(Over fitting 현상). 일반적으로 모델링을 위한 최소한의 데이터 개수는 사용된 입력 변수의 10배정도로 알려져 있다(Neuralware, 2001). 예를 들어, 15개의 입력 변수를 사용한 적절한 신경망 모델링을 위해서는 최소 150개의 학습 데이터 개수가 필요하다. 본 연구에서는 선형 설계가 수행되기 이전 단계에서 선형과 추진기의 전역적인 정보만 포함한 경우와 선형 설계가 수행된 후 선형과 추진기의 국부적인 기하학적 정보를 포함한 경우의 신경망 모델링을 수행하였다.

### 3.1 선형 설계 이전 단계에서의 신경망 최적 구조

선주의 요구 조건에 대해 신속하게 대응하기 위해 초기 설계 단계에서 선형이 없이 기본적인 정보 즉, 주요치수와 선형 요소, 선속만으로 선박의 성능을 가능한 정확하게 추정해야 할 경우가 많다. 이에 본 연구에서는 Table 1에서와 같이 선형과 추진기의 전역적인 입력 변수들을 이용하여 선박의 성능을 추정하는 신경망 모델링을 수행하였으며, Holtrop and Mennen (1982)에서 사용된 설계 변수들과 동일하게 적용하였다. Table 1에서 소개된 입력 변수들은 일반적으로 선주로부터 쉽게 주어지는 설계 조건들로서, 9개의 선형 입력 변수, 3개의 추진기 입력 변수들을 나타낸다. 그리고 출력 변수들로는 수면 위의 정면 면적(Transverse projection area), 침수 표면적(Wetted surface

**Table 2** Ship types and ranges used for the modeling of neural networks

Ship type	Range of particulars	
	Length [m]	<i>C<sub>b</sub></i>
Tanker	210 ~ 330	0.70 ~ 0.82
Container	160 ~ 330	0.54 ~ 0.67
LNGC	266 ~ 274	0.74 ~ 0.76

**Table 3** Neural networks' modeling results before the hull form design

No. of hidden layer	No. of first optimal hidden neuron	No. of second optimal hidden neuron	No. of third optimal hidden neuron	Average error
1	6	-	-	0.111
2	6	3	-	<b>0.068</b>
3	6	3	3	0.093

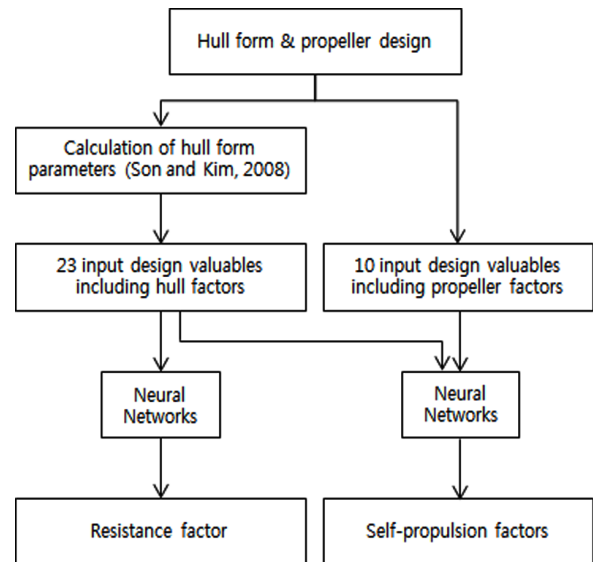
area)을 포함한 6개의 저항과 자항 계수들로 구성되었다. 신경망 모델링을 위해 97척의 실적선 - 41척의 탱크선(Tanker), 39척의 컨테이너선(Container ship), 17척의 가스운반선(LNGC) - 과 프로펠러 조합을 통해 232개의 데이터가 사용되었으며, 학습 수렴 횟수는 1,000번을 기준으로, 평균 추정 오차(출력패턴과 목적 패턴의 차이)의 변화율이 0.01%이하가 될 때까지 반복적으로 수행하였다. Table 2는 학습에 사용된 데이터의 종류 및 주요치수의 범위를 나타낸다.

여기서 학습률, 모멘텀, 은닉층 그리고 은닉층 내의 뉴런 개수는 평균 추정 오차가 최소가 되도록 시행착오(Trial and error)를 통해 순차적으로 수행하였다. 즉, 학습률과 모멘텀을 정의한 후 첫 번째 은닉층의 최적 뉴런 개수를 학습으로 결한 후, 첫 번째 은닉층 구조 내에서 두 번째 은닉층의 뉴런 개수의 최적 구조를 결정하는 순차적 모델링 방법을 사용하였다. 본 연구에서는 대부분 학습률 0.5, 모멘텀 0.4에서 최적 평균 오차를 보였으며, 학습 규칙 EDBD를 적용하였다. 그 결과 Table 3에서 보는 바와 같이 은닉층 개수가 2개, 첫 번째와 두 번째 은닉층의 뉴런 개수가 각각 6개, 3개일 때 평균 추정 오차가 최소값을 나타내었다.

**3.2 선형 설계 이후 단계에서의 신경망 최적 구조**

선형 설계 이후 단계는 선형과 추진기의 기하학적 정보를 포함한 선박의 성능을 추정하는 경우이며, 저항과 추진요소로 분리하여 추정하는 신경망 모델링 구조를 적용하였다. 그 이유는 Table 4에서 보는 바와 같이 선형 설계 이전 단계보다 많은 국부적 설계 변수 - 23개의 선형 정보, 10개의 추진기 정보 - 가 사용되기 때문에 불필요한 정보가 함께 신경망 모델링에 사용될 수 있기 때문이다. 예를 들면, 저항 요소 추정에서 모형 시험에서와 같이 추진기 정보는 필요하지 않으므로 선형 설계 변수들만 신경망 모델링에 사용되었다. 그러나 추진 요소 추정에는 선형과 추진기 설계 변수들이 함께 사용된다. Fig. 2는 선형 및 추진기 설계 이후 신경망을 이용한 성능 요소 추정 흐름도를 나타낸다. 여기서 선형의 형상 파라미터(Hull parameter) 계산 프로그램(Son and Kim, 2008)을 이용하여 계산하였다.

3.1절과 동일하게 동일한 학습 조건으로 232개의 데이터를 사용하여 신경망 모델링을 수행하였다. Table 5와 Table 6은 각 은닉층 개수에서 평균 추정 오차를 고려한 최적 신경망 학습 결과를 나타낸다. 모델링 결과 저항 성능 요소 추정을 위한 최적 신경망 구조는 23개의 선형 입력 설계 변수, 은닉층 개수는 2개, 첫 번째와 두 번째 은닉층의 뉴런 개수는 각각 20개, 14개,



**Fig. 2** Flowchart of the performance prediction by neural networks

1개의 출력 설계 변수( $C_r$ )로 구성하였으며, 추진 성능 요소 추정을 위한 최적 신경망 구조는 33개의 입력 설계 변수(23개 선형 파라미터와 10개 추진기 파라미터), 은닉층 개수는 2개, 첫 번째와 두 번째 은닉층의 뉴런 개수는 각각 24개, 15개, 5개의 출력 설계 변수( $W_{tm}$ ,  $W_{ts}$ ,  $t$ ,  $E_{taR}$ ,  $R_{taO}$ )로 결정하였다. 3.1절과 동일하게 2개의 은닉층을 가지는 구조가 상대적으로 낮은 평균 추정 오차를 가졌다.

**4. 결과 및 분석**

본 연구의 목적은 선박설계에서 모형시험을 수행하기 전에 이루어지는 각 설계단계에서의 신경망을 이용한 성능 요소 추정 방법이 실제 적용이 가능한지를 확인하는 것이다. 이를 위해 3절에서 소개한 최적 신경망 구조를 바탕으로 선형설계 이전 (이하 Before design라 함)과 이후(이하 After design라 함) 설계 단계에서 각 성능 요소를 신경망으로 모델링하여, 학습에 사용되지 않은 12척의 실적선 - 5척의 탱크선(1번~5번), 4척의 컨테이너선(6번~9번) 그리고 3척의 가스운반선(10번~12번) - 에 대해 신경망으로 추정하여 모형시험결과와 비교·분석함으로써 그 실용 가능성을 검토하였다. Fig. 3은 수면 위 선박의 정면면적(Transverse projection area)과 침수표면적(Wetted surface area)의 추정 결과를 나타낸다. 여기서 개선된 Holtrop and Mennen방법은 Holtrop and Mennen방법(1982)에 SSMB의 자

**Table 4** Input-output design variables for the modeling of neural networks after the hull form design

Item	Parameter	Description	Remarks
Input design variable	Type of Ship	0: Tanker, 1: Container ship 2: LNGC	
	<i>LBP</i>	Length between perpendiculars [m]	
	<i>B</i>	Breadth [m]	
	<i>T</i>	Design draft [m]	
	<i>L/B</i>	Length between perpendiculars/breadth	
	<i>B/T</i>	Breadth/design draft	
	<i>L/T</i>	Length between perpendiculars/breadth	
	<i>C<sub>b</sub></i>	Block coefficient	
	<i>LCB</i>	Longitudinal center of buoyancy [m]	
	<i>Tau</i>	U or V shape	Hull factors
	<i>C<sub>w</sub></i>	Waterline area coefficient	
	<i>A<sub>s</sub></i>	$C_m/(L/B)/\sqrt{(B/T)*C_b}$	
	<i>C<sub>pa</sub></i>	Prismatic coefficient in the run part	
	<i>C<sub>pf</sub></i>	Prismatic coefficient in the entrance part	
	<i>E<sub>a</sub></i>	$(L/B)*(1 - C_{pa})$	
	<i>E<sub>f</sub></i>	$(L/B)*(1 - C_{pf})$	
	<i>RA</i>	Run angle[Deg.]	
	<i>EA</i>	Entrance angle [Deg.]	
	<i>SA<sub>AP</sub></i>	Screw aperture from AP [m]	
	Power related factors	<i>NCR</i>	Normal continuous rating [kW]
<i>RPM</i>		Revolutions per minute [rpm]	
<i>V<sub>s</sub></i>		Design speed [knots]	
<i>F<sub>n</sub></i>		Froude number	
No. of Prop.		Number of propeller	
No. of Blade		Number of propeller blade	
Dia. of Prop.		Diameter of propeller	
Pitch		Pitch at 0.7r/R [m]	
Chord		Chord length at 0.7r/R [m]	
<i>E<sub>AR</sub></i>		Expended area ratio	Propeller factors
<i>f/C</i>	Camber/chord at 0.7r/R		
<i>c/D</i>	Pitch/diameter at 0.7r/R		
Rake 1	Forward rake [m]		
Rake 2	Backward rake [m]		
Resistance factors	<i>Cr</i>	Residuary resistance coefficient	Resistance factors
	<i>W<sub>tm</sub></i>	Wake fraction coefficient in the model scale	
	<i>W<sub>ts</sub></i>	Wake fraction coefficient in the full scale	
	<i>t</i>	Thrust deduction coefficient	Self-propulsion factors
	<i>E<sub>taR</sub></i>	Relative rotative efficiency	
	<i>E<sub>taO</sub></i>	Propeller efficiency in open water	

**Table 5** Neural networks' modeling results for a resistance factor after the hull form design

No. of hidden layer	No. of first optimal hidden neuron	No. of second optimal hidden neuron	No. of third optimal hidden neuron	Correlation
1	20	-	-	0.030
2	20	14	-	0.028
3	20	14	14	0.034

**Table 6** Neural networks' modeling results for self-propulsion factors after the hull form design

No. of hidden layer	No. of first optimal hidden neuron	No. of second optimal hidden neuron	No. of third optimal hidden neuron	Correlation
1	24	-	-	0.162
2	24	15	-	0.150
3	24	15	15	0.170

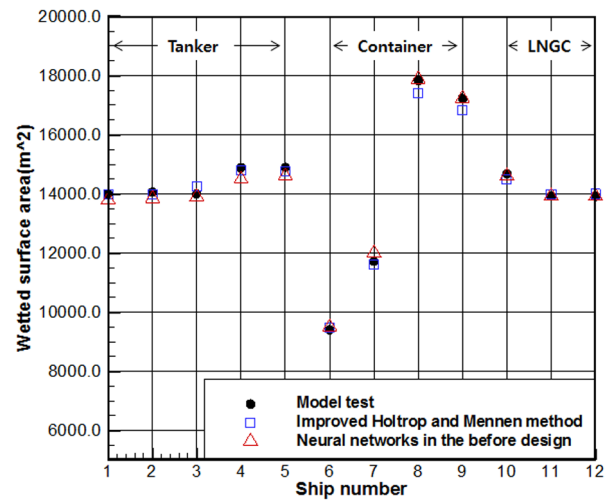
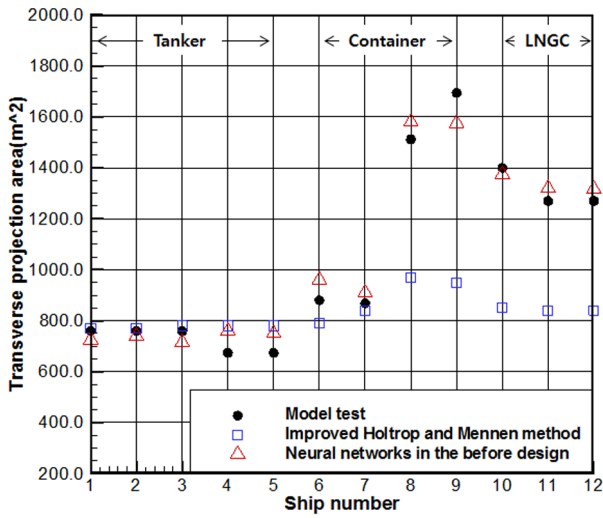


Fig. 3 Comparison of the model test and the neural networks' prediction about transverse area and wetted surface area

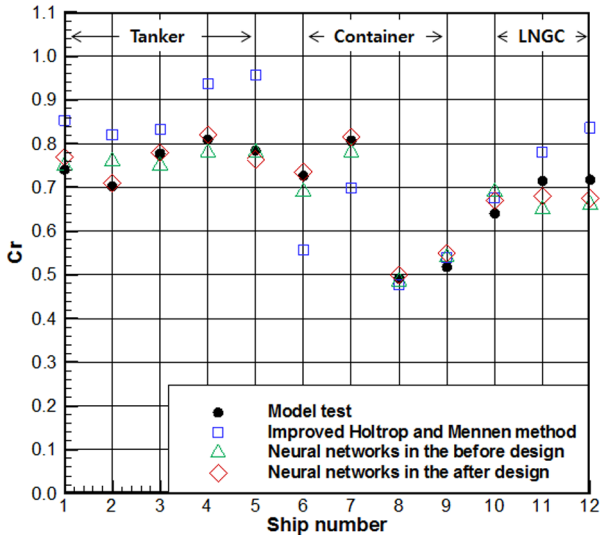


Fig. 4 Comparison of the model test and the neural networks' prediction about Cr

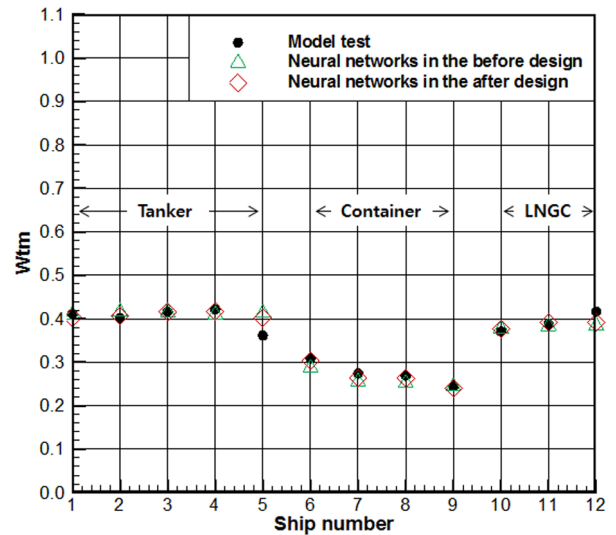


Fig. 5 Comparison of the model test and the neural networks' prediction about Wtm

체 보정계수를 적용한 방법으로 모형시험 결과 대비 정면면적은 평균 19.8%, 침수표면적은 평균 1.1% 오차를 보이는 반면, “Before Design” 신경망의 추정결과는 모형시험 결과 대비 정면면적은 평균 6.0%, 침수표면적은 평균 1.0% 오차를 나타낸다. 두가지 추정 결과가 모두 모형시험 결과를 정성적으로 따르고 있지만, 정면면적 추정 시의 경우 신경망의 모델이 정량적으로 평균 13.8% 정도 더 정확히 추정함을 알 수 있다. 신경망에 의한 정면면적 추정이 침수표면적의 추정에 비해 오차가 상대적으로 크지만, 초기 설계 단계에서 모형시험에 사용되는 수면 위 선박의 정면면적의 추정 또한 실적선 기준선을 바탕으로 추정된다는 관점으로 볼 때 실제 적용에 문제없을 것으로 판단된다.

Fig. 4는 잉여저항계수( $C_r$ )에 대한 모형시험결과와 개선된 Holtrop and Mennen방법, “Before design”단계의 신경망 그리고 “After Design”단계의 신경망 추정 결과를 비교하였다. 여기

서 모형시험 결과와 각각 평균 12.7%, 평균 4.7%, 평균 2.9% 오차를 나타낸다. 신경망 추정 결과가 정성적으로 모형시험 결과와 근사한 값을 가지는데 반해, 개선된 Holtrop and Mennen방법이 상대적으로 과장된 값으로 모형시험 결과의 추이를 따라갈 수 있다. “After design”단계 신경망은 “Before design”단계 신경망에 비해 평균 1.8% 근사한 값으로 추정하는데, 이는 선형 형상에 대한 구체적인 정보가 모델링에 반영되었기 때문이다. 이러한 결과로부터 계속적으로 실적선 모형시험결과가 신경망의 모델링에 사용되어 학습될 경우 국부적 선형 설계 결과가 저항에 미치는 영향을 보다 더 정확히 추정할 수 있을 것으로 기대된다.

Fig. 5는 모형선의 반류계수( $W_{tm}$ )에 대한 모형시험결과와 “Before design”단계의 신경망 그리고 “After design”단계의 신경망 추정 결과를 비교하였다. 여기서 개선된 Holtrop and

Mennen방법은 속도 추정에서 모형선의 반류계수를 사용하지 않기 때문에 제외하였다. Fig. 5에서 “Before design”과 “After design”단계의 신경망 추정 결과가 모형시험결과 대비 각각 평균 4.4%, 평균 2.9% 오차를 가지는데, 선미 형상에 의한 영향이

평균 1.5% 개선되었음을 알 수 있다. 자항 요소가 변화가 저항 요소에 비해 상대적으로 크지 않음을 감안해 보면 선형 요소 영향을 고려한 신경망 추정 결과가 의미가 있는 것으로 판단된다.

Fig. 6~Fig. 9는 실선의 반류계수( $Wts$ ), 추력감소계수( $t$ ), 프로

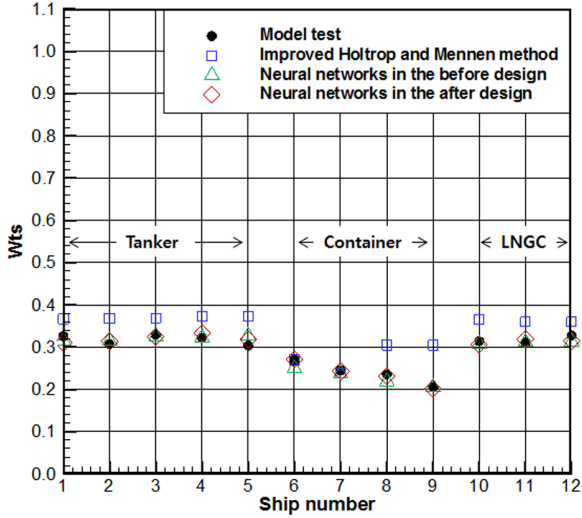


Fig. 6 Comparison of the model test and the neural networks'prediction about  $Wts$

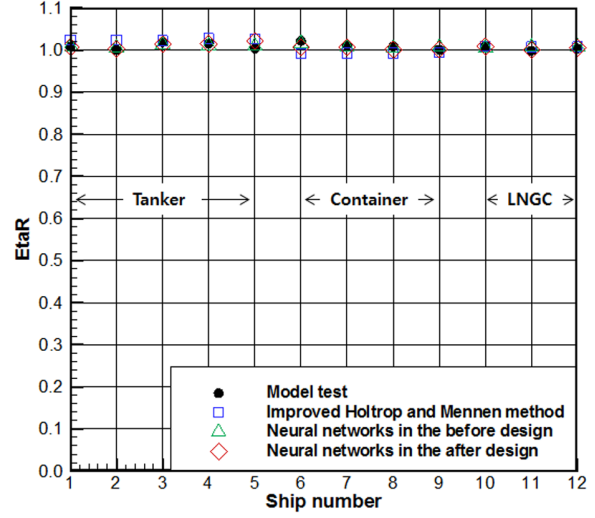


Fig. 8 Comparison of the model test and the neural networks'prediction about  $\eta_{tR}$

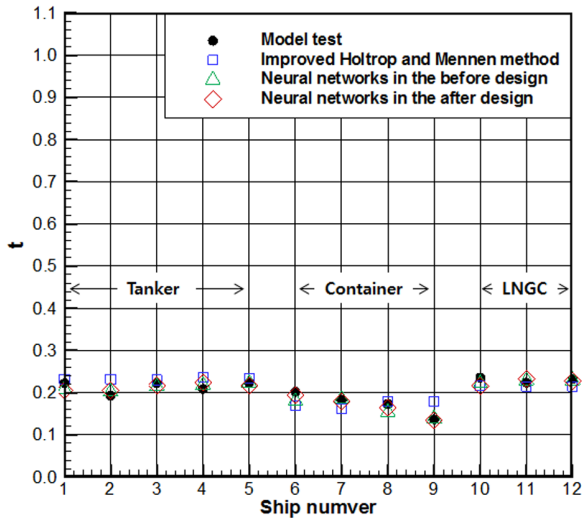


Fig. 7 Comparison of the model test and the neural networks'prediction about  $t$

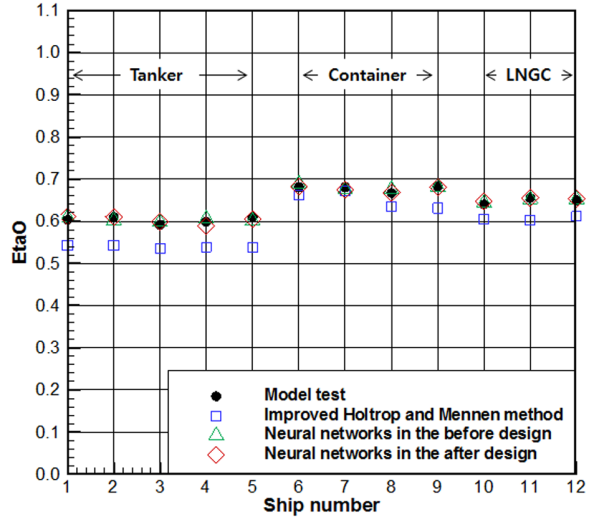


Fig. 9 Comparison of the model test and the neural networks'prediction about  $\eta_{tO}$

Table 7 Errors between Neural networks' modeling result and model test

No. of hidden layer	Average error rate of $Cr$	Average error rate of $Wts$	Average error rate of $t$	Average error rate of $\eta_{tR}$	Average error rate of $\eta_{tO}$
Improved Holtrop and Mennen method	12.7 %	17.1 %	10.7 %	1.4 %	7.4 %
Neural networks in the before design	4.7 %	3.3 %	4.4 %	0.5 %	0.9 %
Neural networks in the after design	2.9 %	2.6 %	4.4 %	0.5 %	0.7 %

펠러상대효율( $\eta_{AR}$ ), 프로펠러 단독효율( $\eta_{AO}$ ) 추정 결과를 나타낸다. 개선된 Holtrop and Mennen방법이 모형시험 결과와 정량적, 정성적으로 차이를 다소 보이는데 반해, 신경망의 추론결과는 정성적, 정량적으로 모형시험결과를 따라가는 것을 알 수 있다.

Table 7에서 전반적으로 신경망이 개선된 Holtrop and Mennen방법에 비해 1.0%~9.0% 추정 정도가 개선되었으며, "After design"단계의 신경망이 "Before design"단계의 신경망에 비해 0.1%~1.8% 추정 정도가 개선된 것을 알 수 있다. 여기서 추력감소계수와 프로펠러 상대효율에 대한 신경망 추정결과는 개선되지 않았다. 이는 본 연구에서 많은 실적선의 선형을 신경망 모델링에 사용하였지만, 유사선형이 많아서 이들 자항요소를 구별할 정도의 충분한 선형 정보가 이용되지 않아서 지속적인 학습이 필요하거나, 선미 형상 파라미터들이 자항요소에 미치는 영향도 평가를 통해 새로운 설계입력변수를 탐색해야 할 것으로 판단된다.

## 5. 결 론

본 논문은 초기 설계 단계에서 선박의 성능 요소들을 보다 정확하게 추정하기 위해 신경망의 최적 구조를 결정하고, 선형 설계 이전과 이후 단계에서 성능 추정시 그 실용 가능성을 다루었다. 선박의 주요치수와 프로펠러 최소 정보를 이용하여 제 성능 요소들을 추정하는 방법(Before design)과 선형 및 프로펠러 설계 이후 기하학적 정보를 사용하여 제 성능 요소들을 추정하는 방법(After design)으로 나누어 신경망을 모델링하였다. 결과를 정리하면 다음과 같다.

첫째, "Before design"단계 즉, 선형설계 이전에 선박의 성능 요소 추정에 신경망을 사용할 경우, 주어진 학습 범위 내에서 개선된 Holtrop and Mennen방법의 성능요소 추정 결과 대비 우수한 정도 향상을 보이고, 모형시험결과와 유사한 정성적 결과를 나타내므로 실용적으로 적용 가능성을 확인하였다.

둘째, "After design"단계 즉, 선형설계 이후에 선박의 성능 요소를 추정하는 경우 주어진 학습 범위 내에서 "Before design" 대비 저항요소는 우수한 정도 향상을 보였다. 그러나 자항요소는 미소한 정도 향상만을 보였다. 이는 선형의 변화에 따른 자항요소의 미세한 변화량을 파악하도록 신경망 구조를 구성하기 위해 학습 데이터의 보완과 함께 선형 파라미터의 영향도 분석이 추가적으로 수행되어야 할 것으로 판단된다. 이때 많은 양의 단순한 데이터 확보보다는 자항요소의 변화를 파악하기 위한 체계적인 선형 정보와 함께 그 모형시험결과가 보완되어야 할 것이다.

셋째, After design단계의 신경망 모델링에 선형과 프로펠러 기하학 정보를 파라미터로 표현하여, 전역적 및 국부적 입력 변수로 사용하였다. 실제 선형 설계에서는 유사 선형을 기준으로 선형을 국부적으로 설계하여 성능을 추정하는 경우가 있다. 예를 들면 동일 선수에 선미 설계를 하거나, 동일 선미에 선수 설계를 수행 할 경우에도 본 연구에서 수행한 신경망은 정성적인 성능 추정이 가능하다.

넷째, 본 연구를 통해 선형설계 전후에 전산 유체 역학(Computational fluid dynamics)이나 모형시험 이전에 신속하게 선박의 성능을 추정하는데 신경망이 실제적으로 적용 가능함을 확인하였다. 체계적인 모형시험 데이터가 축적되어 감에 따라 신경망 모델은 학습 능력으로 인해 계속 개선되어 갈 것이며, 향후 초기 설계 단계에서 안정적인 선박 성능 추정 시스템으로의 역할을 수행할 것으로 기대된다.

## References

- Holtrop, J., Mennen, G.G.J., 1982. An Approximate Power Prediction Method. International Shipbuilding Progress, 29.
- Kanai, T., 2000. Application of the Neural Network to Estimate of Ship's Propulsive Performance and Hull Form Optimization(in Japan). Transactions of The West-Japan Society of Naval Architects, 99, 1-11.
- Kim, S.Y., Kim, H.C., Lee, K.H., Kim, J.N., Son, Y.D., 1995. Determination of Hull form Factors about a High Speed Coastal Fishing Boat using Fuzzy Modeling. Journal of the Society of Naval Architects of Korea, 32(4), 1-8.
- Kim, S.Y., Kim, H.C., 1998. A Development of Neurofuzzy System for a Conceptual Design of Ship. Journal of the Society of Naval Architects of Korea, 35(3), 79-87.
- Kim, S.Y., Kim, H.C., Lee, C.R., 1998a. The Development of Initial Main Particulars and a Hull Form Generation Using a Neurofuzzy Modeling. Journal of Ocean Engineering and Technology, 12(3), 103-111.
- Kim, S.Y., Kim, H.C., Yeo, K.H., Kim, M.J., 1998b. Generation of Sectional Area Curve using an ANFIS and a B-Spline Curve. Journal of Ocean Engineering and Technology, 12(3), 96-102.
- Kim, H.C., Lee, K.S., Kim, S.Y., 1997. Generation of SAC using a ASMOD and a Hybrid Curve Approximation. Journal of The Korean Institute of Intelligent Systems, 11(7), 435-438.
- Kim, S.Y., Lee, Y.S., 1992. Preliminary Hull Form Generation Using Fuzzy Model. Journal of the Society of Naval Architects of Korea, 29(4), 36-44.
- Kim, S.Y., Shin, S.C., Gim, T.G., 2002. Auto Classification of Ship Surface Plates by Neural Networks. Journal of The Korean Institute of Intelligent Systems, 12(2), 103-108.
- Minia, A.A., Williams, R.D., 1990. Acceleration of Back-Propagation through Learning Rate and Momentum Adaption. International Joint Conference on Neural Networks, 1, 676-679.
- Neuralware, 2001. Neural Computing, A Technology Handbook for NeuralWorks Professional II/PLUS.
- Rummelhart, D.E., Hinton, G.E., William, R., 1985. Learning



- Representations by Error Propagation. Institute for Cognitive Science Report 8506, San Diego, University of California.
- Shin, S.C., Kim, S.Y., Park, J.K., 2002. Evaluation of Engine Room Machinery Arrangement using Fuzzy Modeling. *Journal of The Korean Institute of Intelligent Systems*, 12(2), 157-163.
- Shin, S.C., Bae, J.H., Kim, H.S., Kim, S.H., Kim, S.Y., Lee, J.K., 2012. Estimation of Environmental Costs Based on Size of Oil Tanker Involved in Accident using Neural Networks. *Journal of Ocean Engineering and Technology*, 26(1), 60-63.
- Son, H.J., Kim, H.C., 2008. Remodeling of Hull Form and Calculation of Design Parameters using Cubic Composite Spline. *Transactions of the Society of CAD/CAM Engineers*, 13(6), 440-449.