



근사모형을 이용한 해양시스템 성능예측에 관한 연구

A Study on the Performance Prediction of Marine System using Approximation Model

이재철* · 신성철** · 이순섭* · 강동훈* · 이종현*[†]

Jae-chul Lee, Sung-chul Shin, Soon-sub Lee, Dong-hoon Kang and Jong-hyun Lee[†]

*경상대학교 조선해양공학과, **부산대학교 조선해양공학과

*Naval Architecture and Ocean Engineering, Gyeongsang National University

**Naval Architecture and Ocean Engineering, Pusan National University

요약

초기설계 단계에서 시스템의 성능을 고려한 형상의 최적화가 필요하다. 하지만, 일반적으로 공학시스템의 성능예측은 많은 계산 시간이 요구되는 작업이다. 시스템 형상의 최적화를 위해서는 다양한 설계대안에 대한 성능의 평가가 요구되므로 초기 설계과정에서 많은 어려움이 있다. 이러한 문제를 해결하기 위해, 많은 연구자들은 응답표면방법을 이용한 성능예측에 관한 다양한 연구를 시도하고 있다. 하지만, 이 방법은 비선형성이 강한 문제에서 예측오차가 비교적 크게 발생하는 단점이 있다. 따라서 본 연구의 최종목표는 초기설계과정에서 성능예측을 위한 적절한 근사모형을 제시하고, 해양시스템 성능예측 문제(부유식 해상발전기 하부구조물 최적화 문제, 유조선의 선저외판 최적화 문제)에 적용하여 제시된 근사모형을 검증하는 것이다.

키워드: 성능예측, 최적화, 근사모형, 해양시스템

Abstract

In the initial design stage, the geometry of systems needs to be optimized regarding its performance. However, performance analysis is very time-consuming. Therefore, optimization becomes difficult/impossible problems because we need to evaluate the system performance for alternative design cases. To overcome this problem, many researchers perform prediction of system performance using the approximation model. The response surface method (RSM) is typically used to predict the system performance in the various research fields, but it presents prediction errors for highly nonlinear systems. The major objective of this paper is to propose a proper prediction method for marine system problems. Case studies of marine systems (the substructure of a floating offshore wind turbine considering hydrodynamic performance and bulk carrier bottom stiffened panels considering structure performance) verify that the proposed method is applicable to performance prediction in marine systems.

Key Words : Performance prediction, Optimization, Approximation model, Marine systems

Received: Jul. 1, 2016

Revised : Aug. 1, 2016

Accepted: Aug. 3, 2016

[†] Corresponding authors

gnujhlee@gnu.ac.kr

본 논문은 해양산업연구소 신진연구회 연구비와 2016년도 정부(교육과학기술부)의 재원으로 한국연구재단(No. 2016-0030671)의 지원을 받아 수행된 연구임.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

공학 시스템(Engineering system)의 형상은 성능과 밀접한 관계가 있다. 최근 많은 공학 분야에서 시스템의 성능을 분석하기 위하여 컴퓨터를 이용한 시뮬레이션에 의존하고 있다. 일반적으로 조선해양공학(Naval architecture & Ocean engineering; NAOE) 문제를 포함한 공학시스템의 최적설계문제는 다목적 최적화 문제로 구성되어있고, 요구되는 성능과 형상이 복잡해짐에 따라 성능해석에 많은 시간이 요구된다. 이러한 문제를 해결하기 위해, 많은 연구자들은 근사모형(Approximation model)을 이용한 성능예측에 관한 다양한 연구를 시도하고 있다.

반응표면법(Response surface method; RSM)은 전통적으로 시스템의 성능예측에 적용된 방법이다. Bucher와 Bourgund[1]은 RSM을 이용하여 구조물의 신뢰성 문제를 다루었고, Kahraman[2]은 AISI 4140 강의 선삭공정(turning process)에서 절삭 파라미터와 표면 거칠기의 관계를 예측하기 위하여 RSM을 이용하였다. 또한 Yu et al.[3]은 RSM을 이용하여 선박 구조의 피로 신뢰성에 관한 연구를 시도하였다. 하지만, RSM은 비선형성이 강한 문제의 성능예측에 있어 큰 오차가 발생한다는 문제점을

지니고 있다. 최근에는 RSM의 단점을 보완하기 위해 다양한 방법을 적용하여 예측 정확도를 높이기 위한 연구가 활발히 진행되고 있다. Shin[4]은 뉴로-퍼지 알고리즘(Neuro-Fuzzy algorithm)을 이용하여 선박의 후류(Wake)분포의 추정을 시도하였고, Xu[5]는 인공신경망(Artificial neural network; ANN)을 이용하여 해상 안전의 예측을 시도하였다. Lee[6]는 유전적 프로그래밍(Genetic programming; GP)를 이용하여 파랑 중 부가저항(Added resistance)의 예측을 시도함으로써, 인공지능기법의 적용가능성을 분석하였다. 또한, Yang et al.[7]은 크리깅 방법(Kriging method)을 적용하여 동적 제약 조건에 따른 해상 풍력 터빈의 삼각대 하부의 신뢰성 기반 최적설계 연구를 진행한바 있다.

다양한 공학분야에서 근사모델을 이용한 성능예측의 연구가 활발히 진행되고 있는 반면, 조선해양공학 분야에서 관련된 연구는 제한적이다. 따라서, 조선해양시스템 설계문제에 적합한 근사모델 분석 및 적용에 관한 연구가 필요하다. 본 연구에서는 조선해양시스템의 성능예측에 적합한 근사모델 생성을 위하여, 보간적 방법, 회귀적 방법과 인공지능방법(Artificial intelligence method; AI)에 의해 생성된 근사모델의 예측 정확성을 분석하고, 예측하고자 하는 해양시스템의 성능(구조, 유체)에 따라 적합한 근사모델을 제안하고자 한다. 제안된 방법을 바탕으로 조선해양공학 문제(유조선의 선저외판의 최종강도 및 부재 중량 추정, 부유식 해상발전기 하부구조물의 중량 및 인장력 추정)에 적용하여 시스템 설계과정에서의 적용 가능성과 유효성을 확인할 것이다.

본 논문의 2장은 보간모델, 회귀모델과 AI방법(ANN, GP)의 성능예측 정확성 분석을 위해 비선형 수학적함수에 적용하여 결과를 비교/분석하고, 3장에서는 제안된 근사모델을 이용하여 조선해양시스템 성능 예측 문제(유체성능 및 구조성능)에 적용에 관한 내용에 대해 기술한다. 마지막으로 4장에서 결론 및 향후 연구 내용을 기술한다.

2. 근사모델 (Approximation model)

근사모델이란 시스템 설계과정에서 입력(Design variable)과 출력(System performance)사이의 관계를 수학적인 모델로 근사화하는 방법이다. 근사모델은 응답의 특성에 따라 보간모델과 회귀모델로 분류할 수 있으며, 보간모델의 경우 스플라인(Spline), 크리깅 등의 기법들이 있고, 회귀모델로는 다항회귀식(Polynomial Regression model), SVR(Support Vector Regression) 등의 기법들이 있다. 근사모델의 정확성은 어떠한 방법(보간모델, 회귀모델, AI 방법)을 사용하는지에 따라 편차가 발생한다. 따라서, 계산량과 정확도의 측면에서 적절한 방법의 분석이 필요하다.

본 연구에서는 다항식 모델을 이용한 반응표면법, 크리깅 방법, 인공 신경망과 유전적 프로그래밍 방법을 이용하여 근사모델을 생성하고, 각 기법에 의해 생성된 근사모델의 예측 정확성을 비교/분석한다. 크리깅 방법은 목표 지점에서 특성치를 알기 위해 이미 알고 있는 주위의 값들의 가중선형조합으로 그 값을 예측하는 지구 통계적 기법으로써, 보간을 위해 주위의 실측 값들을 선형으로 조합하며, 이러한 통계학적인 방법을 이용하여 값을 추정한다. 이 방법은 값을 추정할 때 실측 값과의 거리 뿐만 아니라 주변에 이웃한 각 측정 값 사이의 상관강도를 반영한다. 인공 신경망 방법은 입력층(Input layer)-은닉층(Hidden layer)-출력층(Output layer)을 이용하여 다중 입력과 다중 출력 사이의 비선형성 관계 정의에 적합하고, 함수들 간의 관계를 뉴런 사이의 전달함수에 의해 근사치를 추측하는 방법이다. 또한 유전적 프로그래밍 방법은 자연 생태계의 진화 현상과 유전학에 근거하여 근사모델을 생성하는 방법이다. 이 방법은 Tree 구조를 사용하여 프로그램을 표현하는 최적화 알고리즘으로써, 복잡한 계산도 수행이 가능하다는 장점을 가지고 있다. 지면 관계상 사용된 각 방법에 대한 보다 상세한 내용은 참고 문헌[8, 9, 10, 11]을 참조하기 바란다.

2.1 근사모델의 추론 정확성 분석

식(1)을 이용하여 반응표면법(RSM), 크리깅, 인공 신경망(ANN)과 유전적 프로그래밍(GP) 방법의 예측 결과를 비교/분석하였다.

Problem: Bazarraa function [12]

$$f(x_1, x_2) = (x_1 - 2)^4 - (x_1 - 2x_2)^2$$

$$s.t. \quad x_1^2 - x_2 \leq 0$$
(1)

Table 1의 학습 데이터(Training data)를 이용하여 근사모델을 생성하고, Table 2의 테스트 데이터(Test data)를 이용하여 생성된 근사모델의 예측 정확성을 확인한다.

표 1. 학습 데이터
Table 1. Training data set

Case	Design variables		Desire
	x_1	x_2	$f(x_1, x_2)$
1	0.000	0.000	16.000
2	0.000	0.200	16.160
3	0.000	0.400	16.640
5	0.000	0.800	18.560
6	0.000	1.000	20.000
7	0.200	0.200	10.538
9	0.200	0.600	11.498
10	0.200	0.800	12.458
11	0.200	1.000	13.738
13	0.400	0.400	6.714

14	0.400	0.600	7.194
15	0.400	0.800	7.994
17	0.600	0.400	3.882
18	0.600	0.600	4.202
19	0.600	0.800	4.842
21	0.800	0.800	2.714
22	0.800	1.000	3.514

표 2. 테스트 데이터
Table 2. Test data set

Case	Design variables		Desire
Case	x_1	x_2	$f(x_1, x_2)$
4	0.000	0.600	17.440
8	0.200	0.400	10.858
12	0.400	0.200	6.554
16	0.400	1.000	9.114
20	0.600	1.000	5.802

RSM을 생성하기 위해 이차 다항식 모델을 사용하였고, 식(2)는 다항 회귀식을 이용하여 생성된 근사곡면을 보여준다.

$$F(x_1, x_2) = 0.6876 + (-0.1624 \times x_1) + (0.02724 \times x_2) + (0.0346 \times x_1^2) + (-0.00842 \times x_1 \times x_2) + (0.009073 \times x_2^2) \quad (2)$$

크리깅을 이용한 근사모델은 정규 크리깅(ordinary kriging) 방법을 사용하였고, 상관관계함수는 가우시안프로세스(Gaussian process)를 사용하였다. ANN을 이용한 근사모델의 생성을 위해 신경망의 구조는 Fig. 1과 같고, 5000번의 학습횟수를 사용하여 근사모델을 생성하였다.




그림 1. 인공 신경망 구조
Fig. 1. Structure of ANN

마지막으로 GP의 근사모델 생성에 필요한 파라미터는 Table 3의 값을 활용하였고, 식(3)은 GP를 이용하여 생성된 근사모델을 보여준다.

$$F(x_1, x_2) = (1.007 \times x_2)^2 \times 0.2577 - (0.2577 \times x_2) + (x_1 - (1.007 \times x_2))^2 \times 0.189 + (0.5927 \times \tanh(\sin(x_1))) \times (\sin(x_1) - 4.507) + 2.011 \quad (3)$$

표 3. 유전적 프로그래밍의 파라미터
Table 3. Parameters of GP

Population size	100
Number of generations	500
Max tree depth	4
Using function set	TIMES, MINUS, PLUS, SQUARE, TANH, SIN, COS

Table 4와 Fig. 2는 각 방법에 의해 생성된 근사모델의 예측 정확성을 보여준다. 여기서 오차(Error)는 식(4)를 이용하여 계산한다.

$$Error = \frac{[(Calculation) - (Desire \text{ or } Prediction)]}{(Calculation)} \quad (4)$$

표 4. 근사모델의 예측 오차
Table 4. Prediction error of approximation models

Case	Prediction error			
	RSM	Kriging	ANN	GP
4	7.529	17.141	17.096	17.427
8	6.843	10.300	11.288	10.884
12	6.208	6.729	6.517	6.548
16	6.698	9.583	8.937	9.059
20	6.203	5.955	5.787	5.730
RMSE	4.908	0.367	0.259	0.241

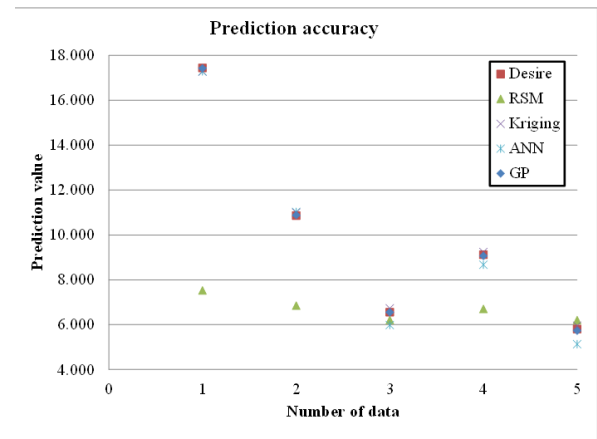


그림 2. 예측 정확성
Fig. 2. Prediction accuracy

2.2 결과 분석

조선해양시스템의 설계문제는 다양한 설계변수와 비선형성이 강한 성능들이 고려되어야 한다. Table 4의 결과를 분석해보면, RSM과 크리깅 방법에 의한 예측 오차가 비교적 크게 나타남을 알 수 있다. 따라서, 본 연구에서는 예측 오차가 비교적 작은 ANN(약 2%) 방법과 GP(약 1.2%) 방법을 이용하여 조선해양시스템의 성능예측을 시도한다.

3. 사례연구

본 연구의 최종목표는 근사모델을 이용한 조선해양시스템의 성능예측이다. 따라서, 본 장에서는 제안된 방법을 바탕으로 비선형성이 강한 조선해양공학 문제들에 적용하여 유효성을 확인한다.

근사모델을 이용한 성능예측의 순서는 아래와 같이 2단계로 나누어진다:

(1st 단계: 형상정의)

설계대안의 체계적인 생성을 위하여 직교배열표[13]를 사용하였고, 설계대안의 성능해석 결과를 이용하여 근사모델을 생성한다.

(2nd 단계: 근사모델 생성 및 예측)

AI방법(ANN, GP)을 사용하여 근사모델을 생성한다. 해양시스템 구조물의 설계과정에서 설계대안의 정확한 성능 예측을 위해 근사모델의 생성이 가장 중요하다. 추론하고자 하는 성능에 적절한 근사모델의 생성을 위하여, 각 방법의 특징을 분석하고, 실제 조선해양 구조물의 성능예측에 적용하여 정확성을 비교/분석한다. 생성된 근사모델의 성능예측 정확성을 확인하기 위하여, 1st 단계(형상정의)에서 생성된 설계 대안을 학습 데이터와 테스트 데이터로 분류하여 연구를 진행한다;

학습 데이터(Training data): 근사모델 생성

테스트 데이터(Test data): 성능예측 정확성 확인

3.1 해상풍력발전기 유체성능예측

해상풍력발전기의 유체성능예측(Nacelle acceleration, Line tension)을 위하여 3개의 설계변수(S; the submerged depth of a column (m), H; the height of the cylinder (m), 와 ; the cylinder radius (m))를 고려하였다. Fig. 3은 대상 시스템의 설계 모델의 예를 보여준다.




그림 3. 설계모델의 예
Fig. 3. Example for design case [14]

직교배열표($L_{18}(21 \times 31)$)를 이용하여 생성된 설계대안은 Table 5와 같다. Case 9의 모델을 기준으로 하고, Case 5, 10와 15는 성능예측을 위한 테스트 데이터로 사용한다.

표 5. 설계대안
Table 5. Alternative design cases [14]

Case	Design variables			Desire		Remark
	S	R_B	H	N.A. (g)	Line tension (N)	
1	6	6	20	0.345	1862740.00	-
2	15	6	20	0.185	2295493.50	-
3	6	6	25	0.219	2573576.25	-
4	15	6	25	0.181	2653605.00	-
5	6	6	30	0.206	2876034.25	Test
6	15	6	30	0.169	2977680.75	-
7	6	8	20	0.255	2745077.00	-
8	15	8	20	0.203	3242407.25	-
9	6	8	25	0.237	3153885.75	Base
10	15	8	25	0.190	3817764.75	Test
11	6	8	30	0.218	3825181.00	-
12	15	8	30	0.177	4503894.00	-
13	6	10	20	0.271	3940402.00	-
14	15	10	20	0.212	4247608.00	-
15	6	10	25	0.249	3580220.75	Test
16	15	10	25	0.197	3775073.00	-
17	6	10	30	0.225	6142682.00	-
18	15	10	30	0.183	6036633.00	-

근사모델의 생성을 위해 ANN의 구조는 Fig. 4와 같고, 학습횟수는 20,000회로 설정하였다. 그리고, GP방법의 근사모델 생성에 필요한 파라미터는 Table 6의 값을 활용하였고, 식(5)와 (6)은 GP방법을 이용하여 생성된 근사모델을 보여준다.

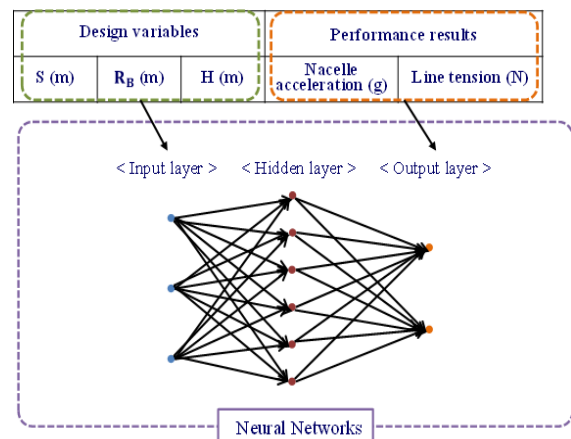


그림 4. 인공 신경망의 구조
Fig. 4. Structure of ANN

표 6. 유전적 프로그래밍의 파라미터
Table 6. Parameters of GP

Nacelle acceleration	
Population size	100
Number of generations	1,000
Max tree depth	5
Using function set	TIMES, MINUS, PLUS, SQUARE, TANH, SIN, COS
Line tension	
Population size	150
Number of generations	5,000
Max tree depth	5
Using function set	TIMES, MINUS, PLUS, TANH, SIN, COS, EXP

(Nacelle acceleration)

$$0.1684 \times \cos(S) \times (S + 3R_B + \sin(S + R_B)) - 0.0676 \times (R_B \times H \times (\cos(S))^2 \times (S + R_B))^2 - 0.1103 \times S \times \cos(S + R_B + 2H) - 698.9 \times \tanh(2S + 3R_B + 3H) + 699 \quad (5)$$

(Line tension)

$$0.01509 \times \exp(4.94 \times R_B \times H) - (0.03945 \times \exp(4.967 \times R_B \times \sin(H))) - 0.01509 \times \sin(5.765 \times R_B \times (S + 5.754)) - 0.5972 / (\exp(0.8139 \times S) \times \exp(0.8139 \times H)) \times \exp(1 \times \tanh(H)) - 0.0003081 \times R_B^2 \times \sin(H) \times (\tanh(S) + 211.7) \times (R_B + H - 18.93) + 0.5982 \quad (6)$$


Table 7, 8과 Fig. 5는 각 근사모델에 의한 성능예측의 결과를 보여준다. 여기서 오차는 식(4)를 이용하여 계산한다.

표 7. 인공 신경망의 예측 오차
Table 7. Prediction error of ANN


Case Case	ANN_Prediction		ANN_Error	
	N.A. (g)	Line tension (N)	N.A.	Line tension
5	0.205	2701608.632	0.007	0.061
10	0.203	3496967.669	0.068	0.084
15	0.252	3771594.132	0.011	0.054

표 8. 유전적 프로그래밍의 예측 오차
Table 8. Prediction error of GP

Case Case	GP_Prediction		GP_Error	
	N.A. (g)	Line tension(N)	N.A.	Line tension
5	0.198	2954814.063	0.039	0.027
10	0.197	3711249.650	0.036	0.028
15	0.255	3697603.149	0.024	0.033



(a) 나셀 가속도
(a) Nacelle acceleration



(b) 선 장력
(b) Line tension

그림 5. 예측의 정확성
Fig. 5. Prediction accuracy

3.2 유조선의 선저외판 구조성능예측

유조선의 선저외판의 구조성능예측(Steel weight, Ultimate strength)을 위하여 5개의 설계변수 (the plate thickness, the web thickness, the flange thickness, the web height와 the flange breadth)를 고려하였다. 5개의 설계변수의 단위는 mm이고, 강재무게(Steel weight; f_1)와 최종강도(Ultimate strength; f_2)의 단위는kg과 MPa이다. Fig. 6은 설계변수를 포함한 예제 모델을 보여준다.




그림 6. 설계 모델의 예
Fig. 6. Example for design case [14]

직교배열표(modified 3-level L 15 array)를 이용하여 생성된 설계대안은 Table 9와 같고, Table 10은 성능예측을 위한 테스트 데이터를 보여준다.

표 9. 학습 데이터
Table 9. Training data set [14]

Case	Design variables					Desire	
	t_p	t_w	t_f	h_w	b_f	f_1	f_2
1	9.5	9	12	138	70	1797.295	0.531
2	9.5	10	15	150	80	1896.766	0.520
3	9.5	12	17	235	90	2162.343	0.575
4	9.5	15	19	383	130	2784.438	0.714
5	9.5	17	20	580	150	3532.079	0.906
6	13	9	15	235	130	2655.170	0.428
7	13	10	17	383	150	3027.784	0.499
8	13	12	19	580	70	3335.210	0.651
9	13	15	20	138	80	2591.593	0.739
10	13	17	12	150	90	2585.155	0.719
11	16	9	17	580	80	3521.717	0.497
12	16	10	19	138	90	2959.981	0.969
13	16	12	20	150	130	3170.833	1.122
14	16	15	12	235	150	3319.718	1.229
15	16	17	15	383	70	3679.615	1.296

표 10. 테스트 데이터
Table 10. Test data set [14]

Case	Design variables					Desire	
	t_p	t_w	t_f	h_w	b_f	f_1	f_2
1'	10	11	13	140	75	1943.946	0.468
2'	12	13	16	200	95	2510.109	0.786
3'	15	16	18	350	120	3557.731	1.027

근사모델의 생성을 위해 ANN의 구조는 5 (Input neuron) - 8 (Hidden neuron) - 2 (Output neuron) 이고(Fig. 7), 학습횟수는 30,000회로 설정하였다. 그리고, GP의 근사모델 생성에 필요한 파라미터는 Table 11의 값을 활용하였다. 식(7)과 (8)은 GP방법을 이용하여 생성된 근사모델을 보여준다.

< Input layer > < Hidden layer > < Output layer >




그림 7. 인공 신경망의 구조
Fig. 7. Structure of ANN

표 11. 유전적 프로그래밍의 파라미터
Table 11. Parameters of GP

Steel of weight	
Population size	100
Number of generations	1,000
Max tree depth	5
Using function set	TIMES, MINUS, PLUS, TANH, SIN, COS, EXP
Ultimate strength	
Population size	500
Number of generations	3,000
Max tree depth	6
Using function set	TIMES, MINUS, PLUS, TANH, EXP

(Steel weight)

$$0.4693 \times t_p - 0.1808 \times t_w - 0.03671 \times \exp(\sin(t_w)) - 0.1086 \times \cos(\tanh(\sin(t_f))) - 0.09211 \times \cos(t_p) + 0.582 \times t_w \times h_w - 0.1086 \times \tanh(\sin(t_f)) \times \cos(h_w) + 0.09211 \times \tanh(\sin(t_f)) \times \exp(b_f) + 0.03671 \times t_w \times \sin(t_w) + 0.4134 \quad (7)$$

(Ultimate strength)

$$\exp(\tanh(1.473 \times t_w)) \times 0.04399 - \tanh(t_p + 2t_w - b_f + b_f \times \exp(\exp(b_f)) - t_w \times (h_w - b_f)) \times 36.92 + \tanh(1.904t_f) \times 0.04399 - 0.04399 \times \exp(t_p) - 0.04399 \times \exp(t_w) + 0.04399 \times t_p \times \exp(\exp(t_p)) + 0.7973 \times (t_p - t_w) \times (t_w + h_w - \exp(h_w)) + 37.33 \quad (8)$$

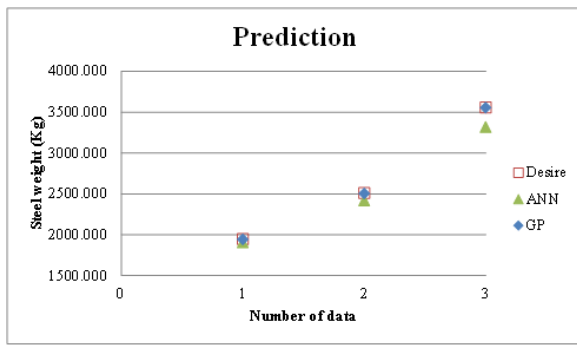
Table 12, 13과 Fig. 8은 각 근사모델에 의한 성능예측의 결과를 보여준다.

표 12. 인공 신경망의 예측 오차
Table 12. Prediction error of ANN

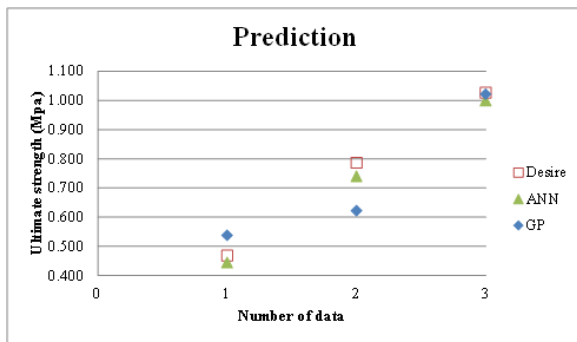
Case	ANN_Prediction		ANN_Error	
	f_1	f_2	f_1	f_2
1'	1904.1620	0.4441	0.0205	0.0504
2'	2417.0438	0.7405	0.0371	0.0579
3'	3315.7740	1.0001	0.0680	0.0261

표 13. 유전적 프로그래밍의 예측 오차
Table 13. Prediction error of GP

Case	GP_Prediction		GP_Error	
	f_1	f_2	f_1	f_2
1'	1940.2597	0.5373	0.0019	0.1489
2'	2503.2420	0.6221	0.0027	0.2084
3'	3553.2323	1.0219	0.0013	0.0050



(a) 강재의 무게
(a) Steel weight



(b) 극한 강도
(b) Ultimate strength

그림 8. 예측의 정확성
Fig. 8. Prediction accuracy

3.3 결과분석

인공지능 기법(ANN과 GP)을 기반한 근사모델을 이용하여 조선해양시스템의 성능예측 결과는 Table 7, 8, 12, 13과 같다. 유체성능 예측 문제의 경우 ANN방법과 GP방법 모두 약 8.4% 이하의 오차를 보였으며, 구조성능의 경우 GP방법을 이용한 결과가 약 21%의 예측 오차가 발생함을 확인할 수 있다. 본 연구에서 적용된 문제를 바탕으로 결과를 분석해보면, ANN방법을 이용하여 생성된 근사모델이 조선해양시스템의 구조/유체성능의 예측에 적합한 방법으로 판단된다. 이는 GP 방법에 비해 활성화함수(activation function)를 이용하여 입력 변수와 출력 변수들 간의 비선형적 연관성의 표현이 우수하고, 예측력이 뛰어난 ANN방법의 특징에 의한 결과로 분석된다.

4. 결론 및 향후 연구

본 연구에서는 근사모델을 이용한 해양시스템의 성능예측에 대한 연구를 시도하였고, 결론은 아래와 같다.

1. 비선형 수학적함수를 이용하여 회귀모델(RSM), 보간모델(Kriging)과 인공지능방법에 의한 예측의 정확성 분석을 시도하였다.

AI방법(ANN, GP)에 의해 생성된 근사모델이 반응표면법과 크리깅 방법으로 생성된 근사모델보다 비선형성이 강한 문제에 적합한 것으로 판단된다.

2. AI방법(ANN, GP)을 이용한 근사모델을 조선해양시스템 성능 예측 문제(유체성능 및 구조성능)에 적용하여 유효성을 분석하였다.

인공신경망(ANN)을 이용한 근사모델이 조선해양시스템의 성능예측에 적합한 방법으로 분석된다.

3. 제안된 성능예측 방법은 성능계산 시간의 최소화와 다양한 설계대안 탐색이 가능하므로 초기설계과정에서 성능을 고려한 최적형상을 결정함에 있어서 유용하게 사용될 수 있을 것으로 사료된다.

향후, 성능예측의 정확성을 높이기 위해서는 설계변수의 민감도 분석과 요구되는 시스템의 설계 문제에 적합한 인공신경망(ANN) 구조에 대한 분석이 필요하고, 실제 산업 현장의 적용을 위해서 다양한 문제에 적용한 검증과정이 요구된다.

References

- [1] C.G. Bucher and U. Bourgund, 1990, A FAST AND EFFICIENT RESPONSE SURFACE APPROACH FOR STRUCTURAL RELIABILITY PROBLEMS, *Structural Safety*, Vol. 7, pp. 57-66.
- [2] F. Kahraman, 2009, THE USE OF RESPONSE SURFACE METHODOLOGY FOR PREDICTION AND ANALYSIS OF SURFACE ROUGHNESS OF AISI 4140 STEEL, *Materials and technology*, 43(5), pp. 267-270.
- [3] L. Yu, P. K. Das and Y. Zheng, 2009. A response surface approach to fatigue reliability of ship structures, *Ships and Offshore Structures*, 4(3), pp. 253-259.
- [4] S.C. Shin, 2007, A Study on Prediction of Wake Distribution by Neuro-Fuzzy System, *International Journal of Fuzzy Logic and Intelligent systems*, 17(2), pp.154-159.
- [5] J. H. Xu, 2011, Application of Artificial Neural Network (ANN) for Prediction of Maritime Safety, *Information and Management Engineering Communications in Computer and Information Science*, Vol. 236, pp. 34-38.
- [6] J. C. Lee, J. H. Jeong, and S. C. Shin, 2014, A study on prediction method for added resistance in waves using the

Genetic Programming, *Proceedings of the Annual Autumn Conference*, SNAK: pp.482-490.

- [7] H. Yang, Y. Zhu, Q. Lu and J. Zhang, 2015, Dynamic reliability based design optimisation of the tripod sub-structure of offshore wind turbines, *Renewable Energy*, Vol. 78, pp. 16-25.
- [8] K. Taraman, 1975, Multi machining output - Multi independent variable tuning research by response surface methodology, *International Journal of Production Research*, 13(4), 265-290.
- [9] G. Bohling, 2005, Introduction to geostatistics and variogram analysis, Kansas Geological Survey.
- [10] R. Hecht-Nielsen, 1998, Theory of the back propagation neural network, *International Joint Conference*, vol. 1, 593-605.
- [11] J. R. Koza, 1992, Genetic Programming: On the Programming of Computers by Means of Natural Selection, MIT Press: Cambridge, Mass.
- [12] M. S. Bazaraa, H. D. Sherali, C. M. Shetty, 2006, Nonlinear Programming: theory and algorithms, 3rd edition, John Wiley and Sons.
- [13] P. J. Ross, 1996, Taguchi Techniques for Quality Engineering 2nd, McGraw-Hill.
- [14] J. C. Lee, 2015, Application of Multi-objective Optimization for Marine Systems using NRSM, Ph.D. Thesis, Pusan National University.

저 자 소 개



이재철(Jae-Chul Lee)

2009년 : 울산대학교 조선공학과 공학사
 2011년 : 부산대학교 대학원 조선해양공학과 공학석사
 2015년 : 부산대학교 대학원 조선해양공학과 공학박사

2016년~현재 : 경상대학교 조선해양공학과 교수

관심분야 : Artificial intelligence, System performance, Engineering system optimization
 Phone : +82-55-772-9195
 E-mail : j.c.lee@gnu.ac.kr



신성철(Sung-Chul Shin)

1999년 : 부산대학교 조선공학과 공학사
 1991년 : 부산대학교 대학원 조선해양공학과 공학석사
 2005년 : 부산대학교 대학원 조선해양공학과 공학박사

2012년~현재 : 부산대학교 조선해양공학과 교수

관심분야 : Artificial intelligence, System optimization, Engineering design
 Phone : +82-51-510-2525
 E-mail : scshin@pusan.ac.kr



이순섭(Soon-Sub Lee)

1989년 : 부산대학교 조선공학과 공학사
 1991년 : 부산대학교 대학원 조선해양공학과 공학석사
 2005년 : 부산대학교 대학원 조선해양공학과 공학박사

2008년~현재 : 경상대학교 조선해양공학과 교수

관심분야 : System optimization, ANN, Fuzzy
 Phone : +82-55-772-9191
 E-mail : gnusslee@gnu.ac.kr



강동훈(Donghoon Kang)

1999년 : 부경대학교 조선해양시스템공학과 공학사
 2003년 : 부산대학교 대학원 조선해양공학과 공학석사
 2005년 : 부산대학교 대학원 조선해양공학과 공학박사

2009년~현재 : 경상대학교 조선해양공학과 교수

관심분야 : System performance, Hydrodynamic
 Phone : +82-55-772-9192
 E-mail : kangdonghoon@gnu.ac.kr



이종현(Jong-Hyun Lee)

1999년 : 부산대학교 조선해양공학과 공학사

1991년 : 부산대학교 대학원 조선해양공학과
공학석사

2005년 : 영 국 뉴캐슬 대학 해양공학 공학박사

2012년~현재 : 경상대학교 조선해양공학과
교수

관심분야 : Offshore engineering

Phone : +82-55-772-9194

E-mail : gnujhlee@gnu.ac.kr