

# 신경망을 이용한 선박의 곡가공 외판 분류 자동화

## Auto Classification of Ship Surface Plates By Neural-Networks

김수영 · 신성철 · 김태건

Soo-Young Kim, Sung-Chul Shin and Tae-Gun Gim

부산대학교 조선해양공학과

### 요 약

선박의 가공비를 산정하는데 있어서 선수, 선미의 복잡한 외판 가공은 큰 몫을 차지한다. 이러한 부분의 외판을 효과적으로 분류할 수 있다면 가공비 산정과 가공비를 줄이기 위한 방법을 모색하는데도 도움을 줄 것이다. 본 연구에서는 곡가공 외판을 효과적으로 분류하기 위해 신경망의 패턴분류 특성을 적용시켜 이를 해결해 보고자 한다.

### Abstract

Manufacturing the complex surface plates in Stern and Stem is a major factor in computing the processing cost of a ship. If these parts are effectively classified, it helps to compute the processing cost and find the way of cut-down on the processing costs. This study is intended to effectively classify surface plates. To solve this problem, we apply Pattern Classification of Neural Networks.

**Key words :** Gregory 곡면, 가우시안 곡률, 신경망

## 1. 서 론

선박설계의 목표는 선주로부터 주어지는 기능적 요구 사항을 제한 조건으로 하여 성능이 가장 우수하고 가장 경제적인 선박을 설계하고 건조하는 것이다.

선체기술 중 가장 자동화 정도가 낮은 분야가 바로 굽힘 가공분야인데 이 분야에 있어서 평면굽힘에 대해서는 기계화의 방향으로 그리고 입체굽힘에 대해서는 기능위주의 작업으로 처리하고 가능한 입체 굽힘 작업량이 적도록 선박설계를 하는 방향으로 노력하는 경향이 있다.

외판은 선박 건조의 비용과 속도를 결정하는 부재로서 경제성 평가를 통한 최적 곡면으로 설계하는 것이 바람직하다. 하지만 선형의 3차원적 형상과 성능에 대한 연구는 많이 수행된 바 있어도 곡면의 형상과 공작성에 대한 상관 관계로부터 경제성의 평가에 대한 연구는 거의 이루어져 있지 않았다. 따라서 선체 외판의 곡면 분류를 이용하여 선체 외판의 형상과 이를 가공하는데 들어가는 M/H의 상관관계를 분석하고, 선형에 대한 선체 외판의 가공비를 산정에 의한 선박의 경제성을 평가할 수 있도록 하여서 유체 역학적 성능을 고려한 선체 외판의 곡면이 단순화된 경제적인 선형을 개발이 필요하다.

본 연구에서는 단순화된 경제적인 선형의 개발을 위한 첫 번째 단계로서 선박 외판분류의 자동화에 대해 살펴보고자 한다. 현재 외판 분류 작업은 숙련된 설계자의

경험에 의해 이루어지고 있어 작업이 용이하지 못할 경우가 많고 또한 설계자의 실수가 발생하면 실제 생산현장에 미치는 영향은 매우 크다. 외판분류 자동화가 이루어지면 설계 작업의 효율을 더욱 높일 수 있으며 정확한 외판분류는 생산성을 더욱 높일 수 있다. 또한 외판 분류 작업은 경제성 검토에 있어서도 중요한 역할을 할 수 있다. 이를 위해서 먼저 선박 외판분류의 일반적인 사항들에 대해 알아보고, 신경망의 패턴분류를 이용하여 이에 대한 해결점을 찾고자 한다.

## 2. 선형의 모델링과 외판 분류

### 2.1 선형의 모델링

선박에서 곡률이 가장 심하게 변하는 부분인 선미와 선수 형상의 정확한 표현을 위해서는 사각형의 곡면 조각 외에 다양한 위상을 갖는 곡면 조각을 필요로 한다. 선수미가 갖는 이런 요구조건을 수용하는 Gregory 곡면은 사각형 곡면 조각을 기본으로 하고 삼각형 및 오각형 등의 곡면에 대하여 분할 기법을 이용하여 다수의 곡면으로 구성한 뒤 이들 분할 곡면을 재결합하여 표현할 수 있다.

bicubic Bezier 곡면과 유사하게 20개의 조정점으로 구성되는 Gregory 곡면의 특징은 다음과 같다[1].

- ① Gregory 곡면은 4개의 경계 곡선으로 곡선 형상이 결정된다.
- ② Gregory 곡면의 경계 곡선은 기본적으로 cubic Bezier 곡선이다.

접수일자 : 2001년 6월 19일  
완료일자 : 2002년 3월 5일

그림 1. 선형 모델링

Fig. 1. The modeling of A ship

- ③ 내부의 Gregory point가  $V_{ij}^* = V_{ij}$  ( $i, j=1, 2$ )이면 Gregory 곡면은 bicubic Bezier 곡면이 된다.
- ④ Gregory 곡면은 Bezier 곡면과 같이 Convex hull 특성을 갖는다.
- ⑤ Gregory 곡면은 경계 곡선에서 교차 접선 벡터의 구성이 독립적으로 정의된다.

그림 1은 Gregory 곡면을 이용한 표 1의 선박을 모델링한 것이다.

표 1. 주요치수

Table 1. Principle dimension

Ship	Type	Tanker	
LENGTH	O.A	271.000	m
LENGTH	B.P	260.000	m
BREADTH	(MOULDED)	45.200	m
DEPTH	(MOULDED)	20.200	m
DRAFT	(DESIGNED)	15.100	m
BILGE	RADIUS	2.000	m

2.2 외판 분류

곡면가공에 따른 외판의 특성을 표 2에서와 같이 평판, 1차곡면, 2차곡면, 3차곡면으로 분류한다.



그림 2. 가우시안 곡률 분포  
Fig. 2. The Distribution of Gaussian Curvature

곡면의 곡률은 곡면상의 한 점에서 최대, 최소곡률의 곱으로 표현되는 가우시안 곡률로 나타낼 수 있다. 이때 가우시안 곡률은 곡면의 형상이 볼록 또는 오목이면 양의 값이며 안장모양이면 음, 직접전개가능형상이면 영의 값을 가진다[2].

표 1의 선박의 전체적인 가우시안 곡률의 분포는 그림 2와 같다. 그림 2를 보면 선수와 선미부분에서 가우시안 곡률값이 많이 변하는 것을 쉽게 볼 수 있다.

그리고, 이 선박의 외판에서 대표적인 1차, 2차 그리고 3차 곡면 형상과 그 부분의 Gaussian 곡률분포를 나타내면 그림 3~8과 같다.

표 2. 선형 외판 분류

Table 2. Classification of Ship Hull Surface

평 판	어떤 방향에 대해서도 전혀 곡률이 없는 경우. 선박의 중앙 평형부의 선측 혹은 선저 외판이 이에 해당한다.
1차 곡면	한 방향으로만 곡률을 가지는 외판으로 주로 Press 혹은 Roller Bending Machine으로 가공한다.
2차 곡면	임의의 두 방향에 대한 곡률만을 가지는 것으로 1차 곡가공과 더불어 선상가열 작업이 필요한 외판을 일컫는다.
3차 곡면	임의의 두 방향에 대한 곡률과 더불어 1축에 대한 비틀림도 존재하는 것으로 선박의 외판 중 선수미 Bulb 부분에 주로 사용한다.




그림 3. 1차 곡면의 가우시안 곡률분포  
Fig. 3. Gaussian Curvature Distribution of 1st surface




그림 4. 1차 곡면의 형상  
Fig. 4. Shape of 1st surface

그림 3, 5 그리고 7은 1차, 2차 그리고 3차 곡면의 가우시안 곡률 분포를 나타내고 있고, 그림 4, 6 그리고 8은 그 부분의 곡면의 형상을 나타내었다. 그림에서도 쉽게 볼 수 있듯이 1차 곡면의 경우에는 가우시안 곡률값이 거의 0이고, 2차와 3차 곡면의 경우에는 다양한 값을 가지고 있고, 특히 3차 곡면의 경우에는 매우 복잡한 분포를 나타내는 것을 알 수 있다.

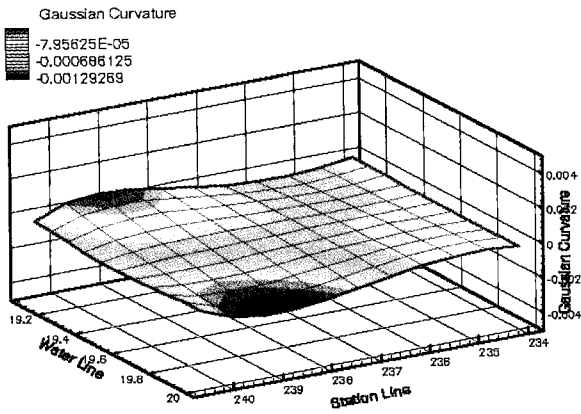


그림 5. 2차 곡면의 가우시안 곡률분포  
Fig. 5. Gaussian Curvature Distribution of 2nd surface




그림 8. 3차 곡면의 형상  
Fig. 8. Shape of 3rd surface




그림 6. 2차 곡면의 형상  
Fig. 6. Shape of 2nd surface




그림 7. 3차 곡면의 가우시안 곡률분포  
Fig. 7. Gaussian Curvature Distribution of 3rd surface

### 3. 분류 자동화

#### 3.1. 신경망

신경망은 반복적으로 입력된 정보에 대하여 각 입력 신호의 가중치를 목적에 맞도록 변화시킴으로써 학습(훈련)을 할 수 있다. 학습을 수행한 신경망 컴퓨터는 입력된 정보를 기억할 수 있으며 인간 두뇌와 같이 비결정적인 특성을 가지고 있기 때문에 약간 틀리거나 비슷한 입

력을 인식할 수 있다. 이러한 특징은 인공지능 분야의 영상인식이나 자연언어처리, 음성인식, 필기체 문자인식 등의 분야에서 매우 유용하다는 평가를 받고 있다 [3][4].

#### 3.2. 외판분류에 대한 신경망의 응용

현재 조선소에서 외판 분류를 하는데 있어서 명확한 기준이 없어서 자동화가 되어 있지는 않다. 따라서 여기서는 이를 자동화하기 위해서 신경망 특성의 하나인 패턴 인식을 적용하였다.

신경망을 이용하기 위해서 가장 중요한 것은 그 특징을 잘 나타낼 수 있는 입력과 이에 대한 정확한 목적 패턴이 필요하다. 선박의 형상이 갖는 3차원 정보를 선체 주위의 흐름, 특히 선미흐름,에 적용하기 위해 선체 표면에서의 각도값을 사용한 경우[5]는 2차원 투영이므로 공간 곡면상의 특성을 완전히 표현 못한다. 곡면 특성을 찾기 위한 다른 예는 곡률 사용으로 외판의 만곡을 찾은 경우 [6]가 있다. 본 연구의 목표는 선체 외판(곡판)의 기하학적 특성을 찾는 것으로, 현장에서의 경험을 토대로 하는 작업에서도 1차, 2차, 3차 곡면 특성은 가우시안 곡률값으로 표현될 수 있었다. 이에 선박의 외판의 형상을 3개의 패턴분류를 하기 위해 입력값으로 곡면의 특징을 잘 표현하는 가우시안 곡률값을 사용하고 이러한 곡면 분류를 신경망의 패턴분류 기능에 의해 해결하고자 한다.




그림 9. 신경망 입력 데이터  
Fig. 9. Input data of This Neural networks

외판의 분류에 있어 가장 효과적인 입력 패턴으로써 외판의 곡률 분포를 생각할 수 있다. 본 연구에서는 학습시 사용되는 데이터는 조선소에서 사용하는 외판분류를 토대로 그 부분의 가우시안 곡률 분포를 입력으로 사용하였다. 여기서 입력 패턴은 외판을 길이 방향으로 그 외판의 길이의 0.2 간격, 폭 방향으로 그 외판의 폭의 0.2 간격으로 총 36개의 지점의 가우시안 곡률 값들과 각각을 0.1 간격으로 121개의 값들로 사용하였다. 그리고 목적 패턴은 1차 곡면, 2차 곡면, 3차 곡면으로 하여 각각의 분류에 대해 11개씩의 입력자료를 준비하여 신경망을 학습시켰다.

입력 데이터는 그림 9에 보는 바와 같이 외판전개도에 근거하여 대표적인 1차, 2차 그리고 3차 곡면의 외판에 대해 위의 방법에 의해 추출 하였고, 학습에 사용한 신경망의 구조도는 그림 10과 같다.

실험의 방법은 표 3과 같이 입력 변수의 개수와 은닉층의 개수에 변화를 주어서 어떤 구조의 신경망이 더욱 효과적인가를 살펴볼 것이다. 이 때 사용할 기준은 정확도와 실험회수로 정확도는 학습된 신경망이 얼마나 잘 추론하는지를 전체 데이터 중에서 정확히 추론한 개수를 퍼센트로 나타내고 학습회수는 실험시 오차를 0.01로 하여 이 오차에 수렴할 때까지의 학습회수(cycle)를 구하여서 이 두 가지를 기준으로 비교하였다.

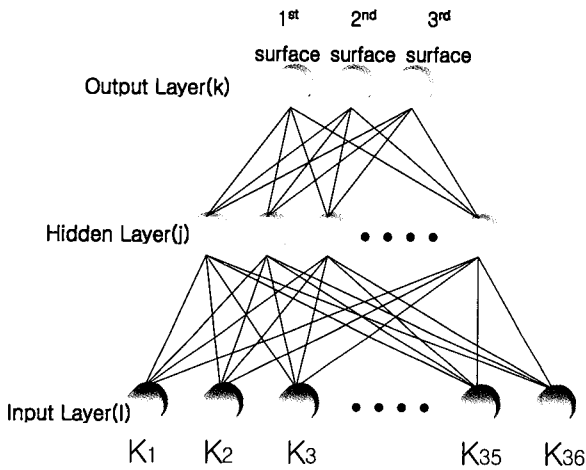


그림 10. 신경망 구조  
Fig. 10. Structure of Neural networks

표 3. 실험 계획

Table 3. The experiment plan

Case	No. of input variable	No. of hidden layer	No. of neuron in hidden layer	
			1st hidden layer	2nd hidden layer
1	121	1	200	.
	36	1	50	.
2	36	1	72	.
	36	1	50	.
3	36	2	50	20
	36	1	50	.

(1) Case 1(입력 변수의 개수가 다른 경우)

외판을 11×11(121개)과 6×6(36개)으로 분할하여 교점

의 가우시안 곡률을 입력 변수로 하고 은닉층이 하나인 경우에 대해 신경망을 학습시켰다.

이것은 입력 변수의 개수에 대한 신경망의 영향을 살펴보기 위해서이다. 이를 학습시켜 추론한 결과는 표 4와 같다.

표 4에서 Input variable은 입력 변수의 개수를 의미하고, 그 아래 Hidden Layer는 은닉층의 개수를 의미한다. 그 뒤의 괄호 안의 숫자는 은닉층의 세포수를 나타내는 것이다. 그리고 Cycle은 학습횟수를 표시하는 것이고, 1st surface, 2nd surface 그리고 3rd surface는 외판 분류 즉, 1차 곡면, 2차 곡면, 3차 곡면을 의미한다. 그 아래의 숫자는 학습한 11개의 데이터들 중에서 정확히 판단한 외판의 개수를 표시하는 부분이고, 오른쪽 아래의 Correct answer은 정확한 판단을 내리는 정도를 나타낸다.

표 4. 신경망 학습 결과

Table 4. The result of training Neural networks

Input variable: 36 Hidden Layer: 1(50) Cycle: 31,312				Input variable: 121 Hidden Layer: 1(200) Cycle: 18,228			
1st surface	2nd surface	3rd surface	Correct answer	1st surface	2nd surface	3rd surface	Correct answer
11	9	11	93.9%	10	11	11	97.0%

즉, 입력 변수가 36개이고 은닉층의 세포수가 50개인 하나의 은닉층을 가진 신경망을 오차 0.01까지 학습시켰을 때, 그 결과는 학습회수(Cycle)가 31,312이고, 각각의 곡면에 대해 1차 곡면은 11개, 2차 곡면은 9개 그리고 3차 곡면은 11개를 정확히 판단하여, 정확도는 93.9%라는 것이다.

표 4에서 보는 것과 같이 입력 변수가 많을수록 많은 정보가 신경망에 주어지기 때문에 보다 정도 높게 추론되고 학습회수도 매우 적다는 것을 볼 수 있다.

(2) Case 2(은닉층의 세포수가 다른 경우)

은닉층이 하나인 경우에 있어서, 은닉층 내의 세포수가 다를 경우에 대해 살펴보도록 하자. 이때 세포수는 50개인 경우와 72개인 경우로 나누어 학습시킨다. 이것은 은닉층의 세포수가 출력에 어떠한 영향을 미치는지를 살펴보기 위해서이다.

표 5. 신경망 학습 결과

Table 5. The result of training Neural networks

Input variable: 36 Hidden Layer: 1(72) Cycle: 26,595				Input variable: 36 Hidden Layer: 1(50) Cycle: 31,312			
1st surface	2nd surface	3rd surface	Correct answer	1st surface	2nd surface	3rd surface	Correct answer
11	9	11	93.9%	11	9	11	93.9%

학습을 시킨 결과 표 5와 같이 외판분류에 있어 은닉층의 세포수의 증가로 인해 정확도에는 영향을 미치지 않지만 학습회수에 있어, 세포수의 증가로 인해 더욱 빠

르게 주어진 오차에 수렴하는 것을 볼 수 있다.

(3) Case 3(은닉층이 두 개인 경우)

은닉층이 하나인 경우와 두 개인 경우를 비교했다. 이때 은닉층의 세포수는 은닉층이 하나인 경우 50개와 은닉층이 두 개인 경우 첫 번째 은닉층의 세포수는 50 그리고 두 번째 층의 세포수는 20개로 한 두 가지에 대해 학습 시킨다. 이는 은닉층의 개수와 은닉층의 세포수의 영향을 살펴보기 위해서이다.

표 6을 보면 정확도 수치에서 은닉층이 하나인 경우가 더 높아서 더 효율적인 것 같지만 학습회수를 보면 현저한 차이를 나타내고 있다. 즉, 은닉층의 증가로 인해 외판분류가 더욱 빠르게 이루어지고 이로 인해 학습회수가 적어서 정확도는 다소 떨어졌다는 사실을 알 수 있다.

표 6. 신경망 학습 결과

Table 6. The result of training Neural networks

Input variable: 36 Hidden Layer: 2(50-20) Cycle: 10,445				Input variable: 36 Hidden Layer: 1(50) Cycle: 31,312			
1st surface	2nd surface	3rd surface	Correct answer	1st surface	2nd surface	3rd surface	Correct answer
11	9	10	90.9%	11	9	11	93.9%

(4) Test(같은 선박의 다른 외판에 적용)

지금까지는 학습이 얼마나 잘 되었는지를 살펴보고, 이번에는 위와 같이 학습된 신경망을 이용하여 동일한 선박의 다른 부분의 외판을 분류해 보도록 한다. 각각의 외판에 대해 10개씩의 데이터를 준비한다.

표 7. 신경망 추론 결과

Table 7. The result of testing Neural networks

Input variable: 36 Hidden Layer: 1(50) Cycle: 31,312				Input variable: 121 Hidden Layer: 1(200) Cycle: 18,228			
1st surface	2nd surface	3rd surface	Correct answer	1st surface	2nd surface	3rd surface	Correct answer
9	9	10	93.3%	9	10	10	96.6%

표 7과 8을 보면 학습과정과 거의 동일한 결과를 보이고 있다. 각각의 경우를 비교해 보면 입력 변수가 많고 은닉층이 두 개인 경우 외판분류가 더욱 효율적이라는 것으로 나타났다. 참고로 입력변수가 121개이고 은닉층 세포수가 200개와 100개인 두 개인 경우에 대해 실험한 결과 학습회수는 7,459이고 정확도는 94%로 나왔다.

(5) 결과 분석 및 비교

- Case 1은 입력 변수의 차이에 따른 신경망의 성능을 평가하였다. 결과는 입력 변수가 많을수록 신경망이 더욱 높은 정확도를 보였다. 학습회수도 입력 변수가 증가함에 따라 매우 줄어드는 것을 볼 수 있다.

표 8. 신경망 추론 결과

Table 8. The result of testing Neural networks

Input variable: 36 Hidden Layer: 1(72) Cycle: 26,595				Input variable: 36 Hidden Layer: 2(50-20) Cycle: 10,445			
1st surface	2nd surface	3rd surface	Correct answer	1st surface	2nd surface	3rd surface	Correct answer
9	10	10	93.3%	10	8	9	90.0%

- Case 2는 은닉층의 세포수의 차이에 따른 신경망의 성능을 평가한 것이다. 은닉층의 세포수가 증가함에 대해 오차에 수렴하는 학습회수는 줄어들었지만 정확도에는 거의 영향을 미치지 않았다.
- Case 3은 은닉층의 개수가 신경망의 성능에 미치는 영향을 조사한 것이다. 은닉층의 증가로 인해 오차에 수렴하는 학습회수가 현저히 줄어들었고 학습회수의 감소로 정확도는 다소 떨어졌다.

앞의 실험 결과를 표 9에 나타내었다.

표 9. 실험 결과

Table 9. The result of experiment

Case	No. of input variable	No. of hidden layer	No. of neuron in hidden layer		Correct answer	Cycle	
			1st hidden layer	2nd hidden layer			
Training	1	121	1	200	·	97.0%	18,228
		36	1	50	·	93.9%	31,312
	2	36	1	72	·	93.9%	26,595
		36	1	50	·	93.9%	31,312
	3	36	2	50	20	90.9%	10,445
		36	1	50	·	93.9%	31,312
Testing	1	121	1	200	·	96.6%	18,228
		36	1	50	·	93.3%	31,312
	2	36	1	72	·	93.3%	26,595
		36	2	50	20	90.0%	10,445

하지만 여전히 error를 보이는 이유는 먼저 입력 패턴 선정 상의 문제와 이번에 사용한 외판 전개도에 표시된 곡면분류의 방법에 있는 것 같다. 먼저 입력 패턴 선정 상의 문제라는 것은 신경망을 효과적으로 이용하기 위해서는 가장 효과적인 입력 패턴으로 학습을 시켜야 하는데 어떤 것을 선택하느냐가 신경망에 영향을 줄 수 있다. 그리고 외판전개도에 표시된 곡면분류 방법의 문제라는 것은 신경망에 학습시키기 위해 사용한 데이터가 경험에 의해 분류된 곡면분류 정보를 사용한 것이기 때문에 이로 인한 error일 수도 있다는 것이다.

### 4. 결 론

외판의 분류를 위해 외판의 가우시안 곡률값을 입력으로 하고 분류된 외판을 출력으로 하는 신경망을 학습시켜 보고 이의 적용 가능성을 살펴보았다. 결과로부터 알 수 있는 것은

- ① 신경망의 패턴 분류를 이용하여 선체 외판의 분류가 가능하다.
- ② 이번 연구에서 효과적인 신경망 구조는 입력 변수가 121개이고 두 개의 은닉층을 가진 것이다.
- ③ 이를 이용하여 기존의 경험 지식에 의한 방법보다 효과적이고 능률적으로 외판 분류를 가능하게 할 수 있고 이에 따라 후행작업의 효율도 더 높일 수 있다.
- ④ 또한 외판분류를 이용하여 외판을 가공하는데 필요한 가공비를 좀더 효율적으로 산출할 수 있고 이를 이용하여 경제적인 선형 개발의 가능성을 검토 할 수 있다.

### 참고문헌

[1] Choi, B. K., "Surface Modeling for CAD/CAM", ELSEVIER, Amsterdam-Oxford-New York-Tokyo, pp. 246 - 260, 1991.

[2] Rogers, D. F. and Adams, J. A., "Mathematical Elements For Computer Graphics", McGraw-Hill Publishing Company, international edition, pp. 461 - 464, 1990.

[3] Laurene Fausett, "Fundamentals of Neural Networks: architectures, algorithms, and applications", Prentice-Hall, Inc., pp. 1994.

[4] Valluru B. Rao and Hayagriva V. Rao, "C++ Neural Networks and Fuzzy Logic", Management Information Source, Inc., pp. 103 - 147, 1993.

[5] Hwangbo, S. M., "Statistical Prediction of Wake Fields on Propeller Plane by Neural Network using Back-Propagation", Ship & Ocean Technology, vol. 4, no. 3, pp. 1~12. Sept. 2000

[6] 김원돈, "선형의 기하학적 모델링을 위한 직접순정법에 관한 연구", 대한조선학회논문집, 28권, 1호, pp. 1~11. April, 1991.

### 저 자 소개



김수영(S.Y.Kim)

1974년 : 부산대학교 조선공학과 졸업 (학사)

1977년 : 부산대학교 조선공학과 졸업 (석사)

1987년 : 독일 Technische Universitaet Berlin, Institut fuer Schiffs und Meerestechnik (박사)

1982년~87년 : Technische Universitaet Berlin, Institut fuer Schiffs und Meerestechnik 연구원

1997년~현재 : 부산대학교 조선해양공학과 교수

주관심분야 : 인공지능, 경제성평가, 선형생성

E-mail : SYKim@pusan.ac.kr



신성철(S.C.Shin)

1997년 : 부산대학교 조선해양공학과 졸업 (학사)

1999년 : 부산대학교 조선해양공학과 졸업 (석사)

1999년~현재 : 부산대학교 조선해양공학과 박사과정

주관심분야 : 에이전트 시스템, 인공지능, 최적설계



김태건(T.G.Kim)

2000년 : 부산대학교 조선해양공학과 졸업 (학사)

2000년~현재 : 부산대학교 조선해양공학과 석사과정

주관심분야 : 인공지능, 퍼지