

요트 설계시 선형의 기하학적 특성과 성능 사이의 관련성에 관한 연구

하득기* · 김수영* · 김용재**

*부산대학교 조선해양공학과

**부경대학교 해양스포츠학과

A Study on the Relation between Hull Geometric Characteristics and Performance in the Yacht Design

DEUCK-GI HA*, SOO-YOUNG KIM*, AND YONGJAE KIM**

* Department of Naval Architecture and Ocean Engineering, Pusan National University, Busan, Korea

**Department of Marine Sports, Pukyong National University, Busan, Korea

KEY WORDS: Genetic Programming 유전적 프로그래밍, Geometric Characteristics 선형 특성, Performance 성능

ABSTRACT: *Yacht design is significantly affected by the hull geometrical characteristics. Therefore, it is necessary to closely examine the relation between hull and performance, before considering characteristics of sea condition. In this study, Genetic Programming is used to derive a formula for the relationship between hull geometric characteristics and performance. Using the formula, a new guideline is proposed to determine performance of a yacht.*

1. 서 론

새로운 선형의 개발을 위해서 초기설계 단계에서 요트의 성능을 추정하는 것이 점점 중요해지고 있다. 요트의 초기설계 단계에서 성능을 추정하는 것은 비용을 절감하고 선형을 최적화시키기 위함이다. 이러한 추정에 근거하여 설계자는 모형 시험을 하기 전에 몇 가지 대안들에 대해서 가장 가능성 있는 선형 특성을 선택할 수 있게 된다.

본 연구에서는 D시리즈(Jacobsen and Kracht, 1992) 중에서 D1~D5 선종 선형의 기하학적 특성을 사용하였다. 요트 설계를 위하여 입력되는 설계변수와 출력되는 성능 사이의 관계를 Genetic Programming(Koza, 1990, 1992)을 이용하여 추론하였으며, 이를 D시리즈에 적용하여 그 신뢰성을 확인하였다.

2. Genetic Programming(GP)

2.1 GP 개념

GP는 자연계의 진화과정을 컴퓨터에서 시뮬레이션 함으로써 실세계의 문제를 해결하고자 하는 계산 모형이다. GP의 기본 특성은 어떤 입력을 가지고 원하는 출력을 낼 수 있는 프로그램의 발견에 대한 진화적 접근이다. Fig. 1은 입출력 사이의 비선형적 상호관련성을 결정하는 GP의 개념도를 보여주고 있다.

제1저자 하득기 연락처: 부산광역시 금정구 장전동 산 30

051-510-3277 hasamo3217@hotmail.net

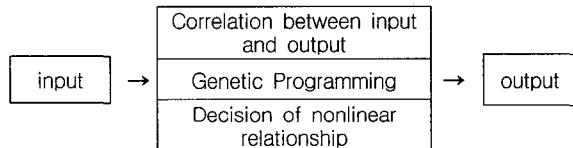


Fig. 1 The Diagram of the GP system

2.2 알고리즘

GP에서는 개체들(individual)이 초기에 생성되며, 이러한 개체들은 다원의 진화 법칙과 적합도(fitness)에 기초한 자연선택의 원리를 따르게 된다.

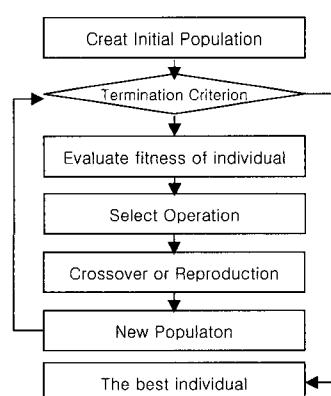


Fig. 2 GP algorithm

(1) 초기 세대 생성

세대는 개체의 집합으로 랜덤하게 초기화된다. 함수노드의 각 가지에 대해 터미널셋과 함수셋 중에서 임의 요소를 선택하여 자손을 형성한다. 함수셋에는 수학 연산자, Boolean 연산자, 조건 연산자, 반복 연산자가 사용될 수 있다. 터미널셋은 숫자변수와 상수로 구성된다. 예를들면 Fig. 3에서 함수셋은 $F=\{+, -, *\}$, 터미널셋은 $T=[X, Z, 0.789]$ 로 구성된다. 트리의 루트를 함수로 선택하면, 필요한 인자만큼의 가지가 형성되고 각 가지마다 함수와 터미널을 선택할 수 있다. 함수가 선택되면 인자의 수만큼 다시 가지가 형성되며 터미널이 선택되면 그 가지는 종결된다.

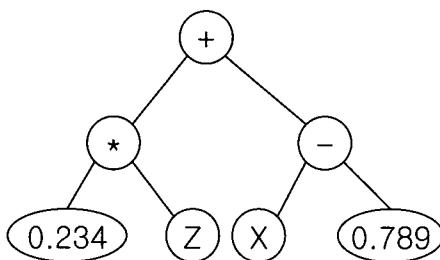


Fig. 3 The representation of an individual

Fig. 3은 LISP(List Processing)형으로 다음과 같이 표현된다.
 $(+ (* 0.234 Z) (- X 0.789))$ 일반적인 수식으로 표현하면 다음과 같다. $0.234 * Z + X - 0.789$

(2) 종료조건

종료조건은 프로그램이 종료할 시점을 결정해 준다. 종료조건에는 최대 세대의 수로 하는 것과 적합도가 가장 좋은 개체를 찾았을 때 종료하는 두 가지 방법이 있다. 이때, 최대 세대의 수와 사용자가 원하는 적합도의 값은 프로그램 수행 전에 지정해 주어야 한다.

(3) 개체 적합도 평가

개체에 의해 평가된 값과 목적함수로 설정된 값의 차이를 말한다.

$$\eta(i, t) = \sum_{j=1}^N |S(i, j) - C(j)| \quad (1)$$

$S(i, j)$: fitness case j 에 대해 개체 i 가 return 한 값

$C(j)$: fitness case j 에 대한 목적함수의 정확한 값

N : fitness case

(4) 연산자 수행

적합도 평가에 의해서 각 개체는 적합도를 가지게 된다. 이러한 적합도에 기초하여 확률적으로 개체를 선택한 후 연산자는 수행된다. 연산자에는 교배와 재생산이 있으며, 연산자의 수행 후에 새로운 세대가 형성된다.

3. 적용 예

3.1 D시리즈에 적용

요트 설계시 GP를 적용하여 성능을 추정하기에 앞서 GP의 성능 추정의 정도를 증명할 필요가 있다. 이러한 목적을 위해 유사 선종 그룹을 대상으로 실험을 수행하는 것이 유익하다. D시리즈는 베를린 모형수조(Berlin Model Basin)에서 선형 특성에 따라 성능이 체계적으로 연구되었다.

3.2 D시리즈의 선형특성과 성능

D시리즈의 기준선 D1의 경우 다음과 같은 선형 특성을 갖는다. 길이/폭 (L/B)=6.0, 폭/흘수 (B/T)=3.75, 체적계수 ($C_v = \frac{\nabla}{L^3}$)= $3.0 \cdot 10^{-3}$, 방형계수 ($C_B = \frac{\nabla}{LBT}$)=0.5, 주형계수 ($C_p = \frac{\nabla}{A_M \cdot L}$)=0.62, 중앙단면계수 ($C_M = \frac{A_M}{BT}$)=0.8, 부심의 위치 $X_{LCB}=0.475*L_{PP}$ (AP로부터). Fig. 4, Fig. 5는 D1의 정면도와 선형을 모델링한 것이다. 설계 Fn은 0.433이지만, 모형선의 경우 Fn은 0.3~0.7에서 측정된 값을 사용하였다.

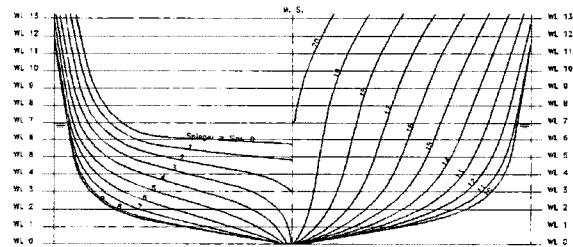


Fig. 4 The body plan of hull D1

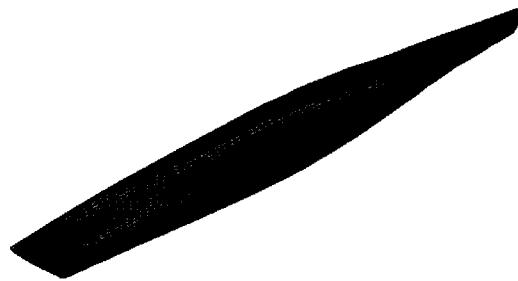


Fig. 5 The modeling of hull D1

선종 D2~D5는 B/T , C_p 및 C_v 를 변화시켜 유도하였다. C_M 과 X_{LCB} 는 변화가 없고, L/B 는 $L/B = \sqrt{C_p C_M / (B/T \cdot C_v)}$ 에서 유도되었다. 각 선종의 선형 특성들을 Table 1에 나타내었다.

Table 1 The hull geometric characteristics

vessel	B/T	C_p	$C_v \cdot 10^3$	L/B	C_B
D1	3.75	0.62	3.0	6.67	0.50
D2	3.75	0.62	3.5	6.17	0.50
D3	4.0	0.62	3.0	6.45	0.50
D4	3.5	0.62	3.0	6.90	0.50
D5	3.75	0.646	3.0	6.81	0.521

선종 D1~D5의 각기 다른 선형 특성으로 인해 모형선의 전저항계수(ctm)도 달라지게 되는데, 이러한 관계를 Fig. 6에 나타내었다.

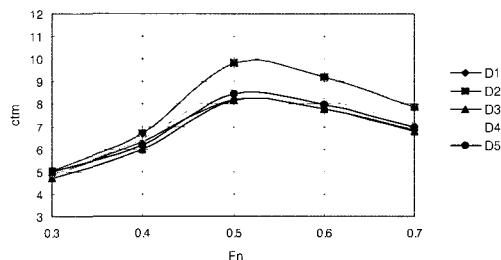


Fig. 6 Total resistance coefficient of model ships

3.3 GP 추론

GP 추론은 3가지 case로 추론되었다. case1은 C_p , case2는 L/B , case3은 B/T , C_p , L/B 의 변화에 따라 성능이 각각 추론되었다. 각 case에 공통적으로 적용된 GP 파라미터를 Table 2에 나타내었다.

Table 2 GP parameters

population size	max generation	crossover rate	reproduction rate	max_depth
100000	100	0.8	0.2	15

(1) case1: C_p 의 변화에 따른 성능 추론

기준선 D1과 C_p 가 다른 D5로 ctm을 추론해 보았다. C_p , Fn 및 ctm이 입력데이터로 사용되었으며, 터미널셋(T)과 함수셋(F)은 각각 다음과 같이 설정되었다. T={ C_p , Fn, random number}, F={+, -, *, /, sin, exp}. 또한, D1의 Fn=0.5, D5의 Fn=0.6이 검증데이터로 사용되었다.

Table 3 Input data

vessel	fitness case	C_p	Fn	ctm	classification
D1	1	0.62	0.3	4.87	learning
	2	0.62	0.4	6.32	learning
		0.62	0.5	8.19	verification
	3	0.62	0.6	7.8	learning
	4	0.62	0.7	6.84	learning
D5	5	0.646	0.3	5.01	learning
	6	0.646	0.4	6.18	learning
	7	0.646	0.5	8.47	learning
		0.646	0.6	7.96	verification
	8	0.646	0.7	7	learning

① GP 추론식

$$ctm = ((C_p, Fn) = ((\sin((Fn/0.42966)*(\exp(\exp(-0.52965))))*(\exp(\exp(0.25036)))) + (((\exp(\exp(C_p)))-((\exp(-0.38545))/((\exp(Fn+Fn))-(C_p+(\sin(C_p))))))) - (((((2*Fn+0.89044)/(0.29079/C_p)))/(((C_p/Fn)+(\sin(-0.88998)))+(0.23311+C_p)))*(\sin(-0.40194)))*((C_p*0.74608)+C_p)))$$

② 추론 결과

Table 4 ctm reasoning according to C_p variation

vessel	Fn	ctm (real)	ctm (reasoning)	error (%)	average of learning error(%)	standard deviation
D1	0.3	4.87	4.837	0.67 ¹⁾	2.15	1.75
	0.4	6.32	6.249	1.13 ¹⁾		
	0.5	8.19	7.884	3.73 ²⁾		
	0.6	7.8	7.637	2.08 ¹⁾		
	0.7	6.84	6.747	1.36 ¹⁾		
D5	0.3	5.01	5.086	1.50 ¹⁾		
	0.4	6.18	6.559	6.13 ¹⁾		
	0.5	8.47	8.215	3.00 ¹⁾		
	0.6	7.96	7.978	0.22 ²⁾		
	0.7	7	7.093	1.32 ¹⁾		

¹⁾ learning ²⁾ verification

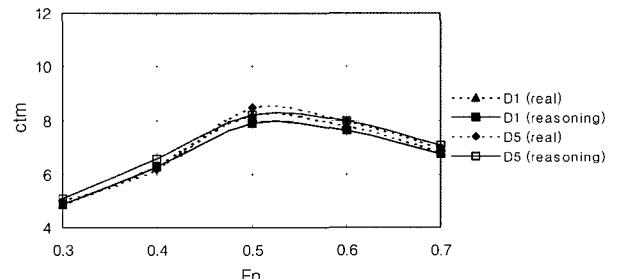


Fig. 7 Comparison of reasoning value and real value

(2) case2: L/B 의 변화에 따른 성능 추론

D1, D3 및 D4의 L/B의 변화에 따른 ctm을 추론하여 보았다. 입력데이터에는 L/B, Fn, ctm이 사용되었으며, 터미널셋(T)과 함수셋(F)은 각각 다음과 같이 설정되었다. T={L/B, Fn, random number}, F={+, -, *, /, sin, exp}. 또한, D1의 Fn=0.5, D5의 Fn=0.6이 검증데이터로 사용되었다.

Table 5 Input data

vessel	fitness case	L/B	Fn	ctm	classification
D1	1	6.67	0.3	4.87	learning
		6.67	0.4	6.32	verification
	2	6.67	0.5	8.19	learning
	3	6.67	0.6	7.8	learning
	4	6.67	0.7	6.84	learning
D3	5	6.45	0.3	4.69	learning
	6	6.45	0.4	5.97	learning
		6.45	0.5	8.17	verification
	7	6.45	0.6	7.78	learning
	8	6.45	0.7	6.8	learning
D4	9	6.9	0.3	4.87	learning
	10	6.9	0.4	6.45	learning
	11	6.9	0.5	8.7	learning
		6.9	0.6	8.19	verification
	12	6.9	0.7	5.65	learning

① GP 추론식

$$ctm = f(L/B, Fn) = (((L/B) + (-0.33270/Fn)) - ((\sin((Fn * ((L/B) + 0.88951)) - (\sin((Fn - 0.31861) * (\sin((Fn * (L/B)) - (\sin(\sin(L/B) * L/B)))) * (Fn - Fn)))) * (B * (0.90912 * (L/B)))) * Fn))) - ((\sin((-0.71862/Fn)/(Fn - 0.31861)) - (\sin((L/B) - 0.42783))))))) \quad (3)$$

② 추론결과

Table 6에 추론 결과를 나타내었다. 또한 D1, D3, D4의 Fn에 따른 학습 및 검증한 결과를 Fig. 8~Fig. 10에 도시하였다.

Table 6 ctm reasoning according to L/B variation

vessel	Fn	ctm (real)	ctm (reasoning)	error (%)	average of learning error(%)	standard deviation
D1	0.3	4.87	4.788	1.68 ¹⁾	2.05	1.86
	0.4	6.32	6.472	2.40 ²⁾		
	0.5	8.19	8.213	0.27 ¹⁾		
	0.6	7.8	8.048	3.17 ¹⁾		
	0.7	6.84	6.839	0.01 ¹⁾		
D3	0.3	4.69	4.579	2.36 ¹⁾		
	0.4	5.97	5.644	5.45 ¹⁾		
	0.5	8.17	7.604	6.92 ²⁾		
	0.6	7.78	7.954	2.23 ¹⁾		
	0.7	6.8	6.704	1.41 ¹⁾		
D4	0.3	4.87	4.932	1.28 ¹⁾		
	0.4	6.45	6.466	0.25 ¹⁾		
	0.5	8.7	8.621	0.90 ¹⁾		
	0.6	8.19	8.079	1.36 ²⁾		
	0.7	5.65	5.963	5.54 ¹⁾		

¹⁾ learning ²⁾ verification

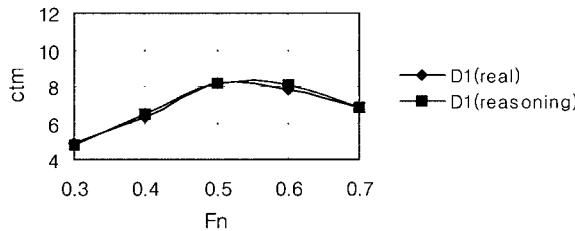


Fig. 8 Comparison of reasoning value and real value in D1

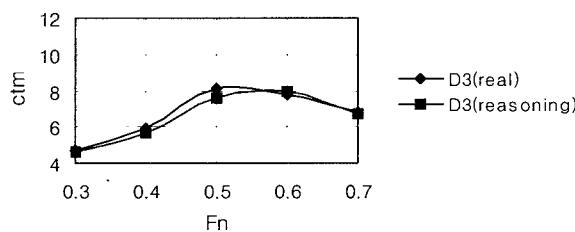


Fig. 9 Comparison of reasoning value and real value in D3

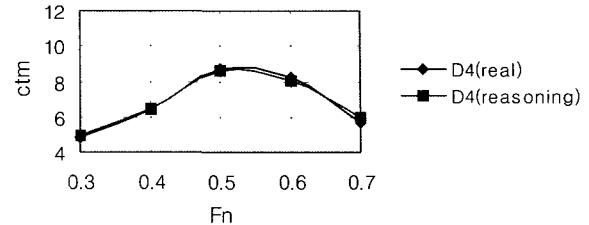


Fig. 10 Comparison of reasoning value and real value in D4

(3) case3: B/T, Cp, L/B의 변화에 따른 성능 추론

D1, D2, D3, D4의 선형 특성들과 성능이 학습에 이용되었다. 추론식의 신뢰성을 확인하기 위하여 D5가 검증데이터로 사용되었다. 터미널셋(T)과 함수셋(F)은 각각 다음과 같이 구성되었다. T={B/T, CP, L/B, Fn, random number}, F={+, -, *, /, sin, exp}

① GP 추론식

$$ctm = f(CP, L/B, B/T, Fn) = (((((((L/B) + (\sin((\exp(0.27675)/Fn)) - (\sin(L/B))) + (\sin((Fn * (B/T)) - (LB + 0.09964))) + ((Fn + 0.50248)/((((L/B)/(L/B)) / (\sin(CP - 0.97705))) + (\sin((\sin((L/B) + ((\sin(B/T)) / ((B/T) + CP)))) + (\sin(Fn)))) - (CP * (((CP + (L/B)) + (\sin(Fn)) / ((Fn - 0.23773) - (L/B)))) * ((\exp(0.68504)) / ((L/B) / ((\sin(B/T)) / (\sin(Fn)))))) + ((\exp(-0.68504)) / ((\sin(CP)) - (\sin(((CP * Fn) * CP) + (0.40663 + (L/B)))))) / ((L/B) * (\exp(CP)))) + (\sin((\exp(Fn) / ((L/B) + (B/T) + 0.34537) - ((L/B) + Fn)))) * (Fn / 0.07539))))))) \quad (4)$$

② 입력데이터 및 추론결과

Table 7 ctm reasoning according to variation of B/T, Cp and L/B

vessel	B/T	Cp	L/B	Fn	ctm (real)	ctm (reasoning)	error (%)	average error(%)	standard deviation
D1	3.75	0.62	6.67	0.3	4.87	4.83	0.83	3.91	2.69
	3.75	0.62	6.67	0.4	6.32	6.45	2.06		
	3.75	0.62	6.67	0.5	8.19	8.57	4.67		
	3.75	0.62	6.67	0.6	7.8	7.91	1.44		
	3.75	0.62	6.67	0.7	6.84	7.03	2.84		
D2	3.75	0.62	6.17	0.3	5.03	5.57	10.64	3.91	2.69
	3.75	0.62	6.17	0.4	6.68	7.06	5.72		
	3.75	0.62	6.17	0.5	9.8	9.08	7.40		
	3.75	0.62	6.17	0.6	9.2	8.38	8.86		
	3.75	0.62	6.17	0.7	7.87	7.72	1.86		
D3	4	0.62	6.45	0.3	4.69	4.46	4.86	3.91	2.69
	4	0.62	6.45	0.4	5.97	6.20	3.89		
	4	0.62	6.45	0.5	8.17	8.34	2.02		
	4	0.62	6.45	0.6	7.78	7.72	0.74		
	4	0.62	6.45	0.7	6.8	6.59	3.15		
D4	3.5	0.62	6.9	0.3	4.87	4.66	4.36	3.91	2.69
	3.5	0.62	6.9	0.4	6.45	6.37	1.30		
	3.5	0.62	6.9	0.5	8.7	8.54	1.81		
	3.5	0.62	6.9	0.6	8.19	7.86	4.05		
	3.5	0.62	6.9	0.7	7.11	7.33	3.15		

③ 추론 검증

검증을 위해 학습에 참여하지 않은 D5의 추론 결과를 Table 8에 나타내었으며, 그 결과를 Fig. 11에 도시하였다.

Table 8 Input data and reasoning results of D5

vessel	B/T	C _p	L/B	F _n	ctm (real)	ctm (reasoning)	error (%)	average error(%)	standard deviation
D5	3.75	0.646	6.81	0.3	5.01	4.78	4.65	2.42	1.85
	3.75	0.646	6.81	0.4	6.18	6.42	3.95		
	3.75	0.646	6.81	0.5	8.47	8.59	1.38		
	3.75	0.646	6.81	0.6	7.96	7.97	0.16		
	3.75	0.646	6.81	0.7	7	7.14	2.00		

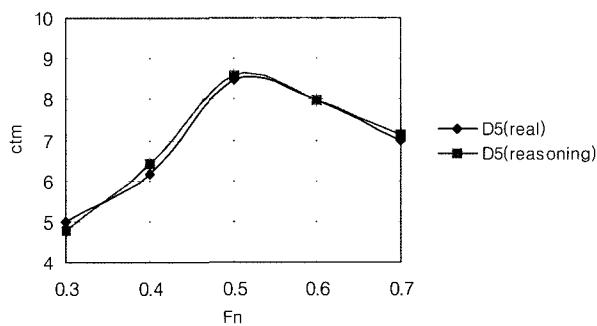


Fig. 11 Comparison of reasoning value and real value in D5

4. 분석정리

(1) case1에서 C_p 선형 특성에 따른 추론은 8가지 학습데이터의 평균 오차율이 Table 4에서 나타내어진 것처럼 2.15%였으며, 학습오차의 표준편자는 1.75였다. 검증데이터로 사용된 D1의 Fn=0.5의 오차율은 3.73%였으며, D5의 Fn=0.6은 오차율이 거의 없는 0.22%였다. Fig. 7의 그림을 통해서 보듯 ctm 추정이 Fn과 C_p의 입력만으로 비교적 정확히 추정될 수 있다.

(2) case2에서 L/B 선형 특성에 따른 추론은 12가지의 학습데이터의 학습오차율의 평균이 Table 6에서 나타내어진 것처럼 2.05%였으며, 학습오차의 표준편자는 1.86였다. 검증데이터인 D1의 Fn=0.4 오차율은 2.4%, D3의 Fn=0.5 오차율은 6.92%, D4의 Fn=0.6 오차율은 1.36%였다. Fig. 9에서 Fn=0.5에서 오차율이 6.92%로 비교적 크지만, 이 데이터는 학습에 의한 데이터가 아니고 검증으로 사용된 데이터이기 때문이다. Fig. 10에서 Fn=0.7의 오차율이 5.54%이었는데, 이러한 오차는 적합도를 증가시키면 줄일 수 있는 값이다.

(3) case3에서 D1, D2, D3, D4의 선형 특성들의 평균학습 오차율은 Table 7에서 나타내어진 것처럼 3.91%였는데 비하여 학습에 참여하지 않은 D5가 평균학습 오차율은 2.42%로 오히려 더 낮았다. 학습오차의 표준편자 역시 1.85로 학습데이터의 2.69보다 낮았다. Fig. 11에서 Fn=0.3에서 추론된 값이 실제 ctm보다 작았으나 Fn이 0.3~0.4에서 실제 값보다 증가하였다. 또한, Fn=0.6 지점에서 거의 일치했으며 Fn이 커짐에 따라 오차가 다시 증가하였다. case3을 통해서 시리즈선의 경우 학습시키지 않고도 선형특성과 ctm의 비교적 정확한 관계를 추정할 수 있음을 알 수 있다.

(4) case1, 2, 3은 모두 입력값들에 따른 출력값(ctm)의 예측이 실용적으로 가능함을 보인다. 그렇지만 case1의 경우가 결과값의 정도 뿐 아니라 입력변수의 최소 개수만을 사용할 수 있는 점에서 사용의 편의성에도 가장 좋다.

5. 결론

본 연구로부터 다음과 같은 결론을 얻었다.

- (1) GP는 C_p, L/B, L/B와 C_p 및 L/B의 선형 특성에 따른 모형선의 전저항계수(ctm)를 추정하는 데 유용하다.
- (2) 요트설계시 모형선 시험 전에 GP를 통하여 성능 추정이 가능하며 따라서 최적화된 선형을 초기에 생성하는 데 도움이 된다.

후기

본 연구는 부산대학교 연구보조비에 의한 연구결과 중 일부임을 밝히며, 연구비 지원에 감사드립니다.

참고문헌

- Jacobsen, A. and Kracht, A.M. (1992). "D-Series, Systematic Experiments with Models of Fast Twin-Screw Displacement Ships", SNAME, Vol 100.
 Koza, (1990). Genetic Programming (I), MIT Press.
 Koza, (1992). Genetic Programming (II), MIT Press.
 Michalewicz, Z. (1992). Genetic Algorithms Data Structures Evolution Programs, Springer-Verlag.

2003년 10월 2일 원고 접수

2003년 11월 14일 최종 수정본 채택