



# 통계적 접근 방법을 이용한 저속비대선 및 컨테이너선의 동력 성능 추정

김유철·김건도·김명수·황승현·김광수·연성모·이영연<sup>†</sup>  
선박해양플랜트연구소

## Powering Performance Prediction of Low-Speed Full Ships and Container Carriers Using Statistical Approach

Yoo-Chul Kim·Gun-Do Kim·Myung-Soo Kim·Seung-Hyun Hwang·Kwang-Soo Kim·Sung-Mo Yeon·  
Young-Yeon Lee<sup>†</sup>  
Korea Research Institute of Ships and Ocean Engineering (KRISO)

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.

In this study, we introduce the prediction of brake power for low-speed full ships and container carriers using the linear regression and a machine learning approach. The residual resistance coefficient, wake fraction coefficient, and thrust deduction factor are predicted by regression models using the main dimensions of ship and propeller. The brake power of a ship can be calculated by these coefficients according to the 1978 ITTC performance prediction method. The mean absolute error of the predicted power was under 7%. As a result of several validation cases, it was confirmed that the machine learning model showed slightly better results than linear regression.

**Keywords** : Power prediction(동력 예측), Linear regression(선형 회귀), Machine learning(기계 학습), Hull form variables(선형 변수), Fullship(저속비대선), Container carrier(컨테이너선)

## 1. 서론

회귀식 등 통계적 방법을 이용하여 선박의 주요제원으로 실선 동력 성능을 추정하는 것은 선박의 기본 설계 단계에서 주요제원의 선정을 위해서 사용할 수 있는 유일한 방법이다. 물론 선박의 성능 추정을 위해서는 모형 시험이나 CFD(Computational Fluid Dynamics)를 활용하는 것이 더 정확한 예측을 가능하게 하는 방법이지만, 선도(lines)가 정해지지 않은 단계에서는 이용할 수 없는 방법이며, 많은 수정이 이루어지는 초기 단계에서 빠른 피드백 시간을 제공할 수 없다. 따라서 통계적인 접근 방법은 정확도가 제한적임에도 불구하고 초기 설계 단계에서 여전히 유용하게 활용되고 있다.

이러한 통계적 접근 방법의 대표적인 것으로 Holtrop의 방법(Holtrop and Mennen, 1978; Holtrop and Mennen, 1982; Holtrop, 1984)이 가장 널리 사용되고 있으나, 이 회귀식은 1980 년대에 개발된 것으로 현재 개발되는 선형의 특성이 반영되지 않아

일부 대형 조선소에서는 이 식의 계수들을 자신들의 데이터베이스에 맞도록 조정하여 사용하고 있다. Kim et al. (2019)이 비교적 최근의 KRISO(Korea Research Institute of Ships and Ocean Engineering) 모형시험 데이터를 회귀 분석하여 저속비대선의 잉여저항계수(Cr; residual resistance coefficient) 추정 회귀식을 소개하였으며, Kim et al. (2020)이 잉여저항계수 추정을 위하여 기계학습 기법을 적용한 결과를 발표한 바 있다. 네덜란드의 MARIN(Maritime Research Institute Netherlands)은 Holtrop 방법을 기반으로 선박 추진 성능 예측 프로그램인 QDESP을 제공하고 있으며, 일본의 NMRI(National Maritime Research Institute) 역시 이와 유사한 선박 성능 추정 방법을 보유하고 있다. 최근에는 실선 운항 상태의 성능 예측에서 주목받고 있는 파랑 중 부가저항에 대한 회귀 분석 연구도 활발히 진행되고 있다.

본 연구에서는 선박의 주요제원을 이용하여 초기 설계 시 이용할 수 있는 저항 성능 계수 및 자항 성능 계수에 대한 회귀 추정식과 더불어 근래 데이터 분석에 활발히 활용되고 있는 기계

학습을 이용한 회귀 모델을 소개하고 이를 이용하여 선박의 실선 동력 추정 과정 및 그 결과를 보인다. 2장에서는 모형선 스케일의 저항 및 자항 성능 계수를 이용하여 실선의 동력을 추정하는 과정에 대하여 간략히 소개하며, 3장에서는 이러한 저항 및 자항 성능 계수에 대한 선형 회귀식 결과, 기계학습 기법을 적용하는 과정 및 결과를 보인다. 마지막으로 두 가지 방법을 이용하여 저속비대선 및 컨테이너선의 실선 동력을 추정한 결과를 비교 분석한다.

## 2. 모형선 스케일 성능 계수를 이용한 실선 동력 추정

최근 CFD를 활용하여 실선 스케일의 성능 계수를 직접 예측하는 접근법이 시도되고 있으나, 해석결과 검증을 위한 실선계측 결과의 정확도 한계로 인해 여전히 모형선 스케일의 결과로부터 확장하는 ITTC 성능 예측 방법(International Towing Tank Conference, 1978) 이 사용되고 있다. 본 연구에서도 선박의 주요제원과 모형선 시험 결과의 분석을 통해서 저항 및 자항 관련 성능 계수를 추정하는 바, 유사한 방법을 적용하여 실선의 마력 성능을 예측한다.

통상 실선 동력으로 사용되는 제동 동력(brake power,  $P_B$ )은 전달 동력(delivered power,  $P_D$ )과 전달 효율(transmission efficiency,  $\eta_T$ )의 관계(식 (1))로 얻어지며, 일반적으로 전달효율은 동력전달 과정에서 샤프트 베어링, 스톤 튜브 등의 기계적인 손실에 의해 결정되며, 상선의 경우 주로 0.99가 사용된다. 전달 동력은 저항에 관한 성분인 유효 동력(effective power,  $P_E$ )을 준 추진 효율(quasi-propulsive coefficient,  $\eta_D$ )로 나눈 값으로, 유효 동력은 식 (2)로 정의되며, 준추진 효율은 식 (3)과 같이 선각 효율(hull efficiency,  $\eta_H$ ), 프로펠러 단독 효율(propeller open water efficiency,  $\eta_0$ ), 상대회전 효율(relative rotative efficiency,  $\eta_R$ )의 곱으로 표현된다.

$$P_B = \frac{P_D}{\eta_T} \quad (1)$$

$$P_E = R_{TS} \cdot V_S \quad (2)$$

$$R_{TS} = C_{TS} \cdot \frac{1}{2} \rho_s S V_S^2$$

$$\eta_D = \eta_H \cdot \eta_0 \cdot \eta_R \quad (3)$$

여기서,  $V_S$ 는 실선의 속력,  $C_{TS}$ 는 전저항계수,  $\rho_s$ 는 해수 밀도,  $S$ 는 침수표면적을 나타낸다. 선각 효율은 자항 시험으로부터 얻어지는 반류 계수( $w_m$ )와 추력감소 계수( $t$ )로 계산되고, 프로펠러 단독 효율은 프로펠러 단독 성능 곡선으로부터 계산된다. 상대 회전 효율은 선체가 있을 때와 없을 때의 프로펠러 토오크의 비율(추력일치법을 이용할 경우)로 표현되는데, 본 연구에서는 1.0으로 가정하였다. 따라서, 실선 스케일의 저항계수( $C_{TS}$ ), 반류계수

( $w_s$ ), 추력감소 계수( $t$ ), 프로펠러 단독 성능이 주어지면 실선의 제동 동력 예측이 가능하다.

저항 계수는 2차원 해석법을 사용할 경우 식 (4)와 같이 실선 마찰저항계수( $C_{FS}$ ), 잉여저항계수( $C_r$ ), 상관관계계수( $C_A$ )와 공기저항계수( $C_{AA}$ )의 합으로 정의된다. 실선마찰저항계수는 레이놀즈수(Reynold's number)의 함수로 계산되고, 상관관계계수는 선형 시험수조의 고유값으로 정해지며, 공기저항계수는 상부횡단면적( $A_T$ )을 이용한 추정식으로 계산할 수 있다. 즉, 잉여저항계수를 회귀식 혹은 회귀 모델을 이용하여 주요제원으로부터 추정하면 실선 저항을 예측하는 것이 가능하다.

$$C_{TS} = C_{FS} + C_r + C_A + C_{AA} \quad (4)$$

상관관계계수는 대상선인 저속비대선과 컨테이너선의 상관관계계수를 수선간거리(LBP)의 2차 다항식으로 근사하여 얻어진 값을 사용하였으며, 공기저항계수는 식 (5)를 사용하여 추정하였다.

$$C_{AA} = \frac{0.0006A_T}{S} \quad (5)$$

침수표면적  $S$ 는 식 (6)과 같이 저속비대선과 컨테이너선에 대하여 회귀분석을 통하여 얻어진 값을 이용하였다.  $\nabla$ 는 배수용적(displacement volume)을 의미한다.

$$S_{fullship} = -1.0E-7\nabla^2 + 0.1172\nabla + 2858.2 \quad (6)$$

$$S_{container} = -2.0E-7\nabla^2 + 0.1529\nabla + 1895.0$$

선각 효율은 식 (7)과 같이 반류계수 및 추력감소 계수의 관계로 정의되므로 추정식으로 구한 모형선 스케일의 반류계수를 실선 스케일로 확장(식 (8))하면 계산할 수 있다.

$$\eta_H = \frac{1-t}{1-w_s} \quad (7)$$

$$w_s = (t+0.04) + (w_m - t - 0.04) \cdot \frac{C_{FS} + C_A}{C_{FM}} \quad (8)$$

여기서  $w_m$ 은 모형선 스케일의 반류계수,  $C_{FM}$ 은 모형선 레이놀즈수에 해당하는 마찰저항 계수를 의미한다.

프로펠러 단독 성능 곡선은 보통 프로펠러 단독 시험(propeller open water test)을 통하여 얻어지나, 프로펠러에 대한 상세 정보가 정해지지 않은 상태에서 일반적으로 사용되는 B-시리즈 프로펠러의 회귀식(Carlton, 2007)을 이용하였다. B-시리즈 프로펠러의 성능 회귀식은 모형선 스케일에 맞춘 회귀식이므로 실선 스케일로 확장이 필요한데, ITTC 1978 방법에서는 단면 두께, 코오드 길이 등에 대한 정보가 추가로 필요하기 때문에, 본 연구에서는 실선 스케일로 확장을 레이놀즈수의 변화에 따른 성능 향상 및 모형 시험에서 선형에 맞게 설계된 프로펠러를 사용하는 영향을 고려하여 단순히 B-시리즈 프로펠러의  $K_T$ 를 2% 증가,  $K_Q$ 를 2% 감소하는 방향으로 가정하였다. 이렇게

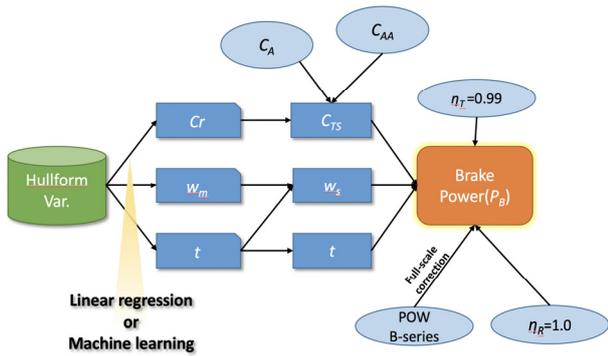


Fig. 1 Flow chart of predicting the brake power using regression

언어진 실선 스케일의 프로펠러 단독성능 곡선에서 총저항에 해당하는 추력(식 (9))과 일치하는 전진비를 찾고, 이 전진비에 해당하는 단독 효율( $\eta_D$ )을 계산한다. 여기서 D는 프로펠러 직경을 의미한다.

$$\frac{K_T}{J^2} = \frac{S \cdot C_{TS}}{2D^2(1-t)(1-w_s)^2} \quad (9)$$

Fig. 1은 선형 변수 데이터베이스를 이용하여 선박의 실선 마력을 추정하는 과정을 보인다.

- 선형 회귀식 혹은 기계학습 모델을 이용하여 선박의 잉여저항계수, 모형선 스케일의 반류계수, 추력감소 계수를 추정한다.
- 잉여저항계수를 이용하여 식 (4)를 통해 실선의 총저항계수를 추정한다.
- 반류계수의 실선 스케일 확장을 통해서 식 (7)을 이용하여 선각 효율을 계산한다.
- 추정된 총저항계수, 반류계수, 추력감소 계수를 식 (9)에 적용하여 프로펠러 단독 효율을 계산한다.
- 식 (3)으로 준추진 효율을 구하고, 식 (1)을 이용하여 제동 동력을 계산한다.

### 3. 회귀를 이용한 저항 및 자항 성능 계수의 추정

본 연구에서는 저속비대선과 컨테이너선에 대한 성능 계수를 추정하기 위하여 선형 회귀 및 기계 학습 모델을 사용하였다. 독립 변수로서 주요제원만을 사용하여 회귀 분석을 실시하였다. 회귀 분석에 사용된 선형은 저속비대선이 약 210척, 컨테이너선이 약 90척이다. 선형에 대한 주요제원으로는 L(수선간 거리, LBP), B(폭, beam), T(흘수, draft), Cb(방형계수, block coefficient), LCB(종방향 부력 중심, Longitudinal Center of Buoyancy, 중앙 횡단면으로부터 거리의 수선간 거리에 대한 비율%)를 사용하였으며, 프로펠러에 대한 변수로서는 Z(날개수), 직경(D), P/D(0.7R에서의 피치비), 전개면적비(expanded area

ratio,  $A_E/A_0$ )를 사용하였다.

잉여저항계수 회귀 모델 도출을 위하여 선형 관련 주요변수의 무차원화 계수(L/B, L/T 등)를 사용하였으며, 식 (10)과 같이  $F_n$ 의 다항식으로 근사한 Cr 추정값 (Kim et al., 2019)도 하나의 독립변수로 사용하였다. 반류계수 회귀 모델 도출에는 선형 변수 외에 추가로 프로펠러에 대한 정보가 추가되었으며, 추력감소 계수 분석에는 속도와 관련된 항의 의존성이 없는 것으로 분석되어 속도 관련 변수는 사용되지 않았다. 즉, 본 연구에서 도출된 추력감소 계수는 속도의 변화와 관계없이 일정한 값을 갖는다.

Full ship: (10)

$$Cr_{poly_{Cb \leq 0.825}} = 1.176 - 16.152F_n + 216.865F_n^2$$

$$- 1092.559F_n^3 + 415.884F_n^4 + 8271.551F_n^5$$

$$Cr_{poly_{Cb > 0.825}} = 4.983 - 112.474F_n + 1267.504F_n^2$$

$$- 4783.943F_n^3 - 2563.743F_n^4 + 41472.808F_n^5$$

Container carrier:

$$Cr_{poly_{F_n \leq 0.18}} = 0.569 - 4.63F_n^2 + 27.923F_n^3$$

$$Cr_{poly_{F_n > 0.18 \quad Cb \leq 0.625}} = -0.922 + 57.709F_n$$

$$- 855.692F_n^2 + 6135.245F_n^3$$

$$- 21329.501F_n^4 + 28906.546F_n^5$$

$$Cr_{poly_{F_n > 0.18 \quad Cb > 0.625}} = -14.93 + 484.134F_n$$

$$- 5887.308F_n^2 + 34880.371F_n^3$$

$$- 101109.965F_n^4 + 115508.137F_n^5$$

### 3.1 선형 회귀에 의한 성능 계수 추정

선형 회귀식을 도출하는 방법은 Kim et al. (2019)의 방법을 사용하였다. 선정된 독립변수(선형 및 프로펠러 변수)와 종속변수(잉여저항계수, 반류 계수, 추력감소 계수)의 상관관계 분석을 통해 관련 있는 독립변수 후보를 선정하고, 회귀 분석 과정을 통해서 유의 확률과 독립변수 간 종속성을 고려하여 최종 회귀식을 도출하였다. 저속비대선과 컨테이너선의 잉여저항계수 추정 회귀식을 식 (11)과 (12)에 각각 보인다. 분석에 사용된 잉여저항계수 데이터 수는 저속비대선 약 2500개, 컨테이너선 약 1070개이다. 저속비대선의 경우 Cb 0.825를 기준으로, 컨테이너선은 Cb 0.65 기준으로 분석 구간을 나누어 회귀 분석을 수행하였다.

$$Cr_{Cb \leq 0.825} = -0.304 + 0.32 \frac{B}{T} Cr_{poly} + 2.002 Cb \quad (11)$$

$$- 0.264 \frac{L}{\nabla^{1/3}}$$

$$Cr_{Cb > 0.825} = 3.002 + 1.229 Cb \cdot Cr_{poly} - 0.27 \frac{B}{T}$$

$$- 0.458 \frac{L}{\nabla^{1/3}}$$

$$Cr_{Cb \leq 0.65} = 1.733 + 0.036 \frac{L}{T} Cr_{poly} - 0.497 \frac{B}{T} \quad (12)$$

$$Cr_{Cb > 0.65} = -1.246 + 0.345 \frac{B}{T} Cr_{poly} + 4.258 Cb$$

$$- 0.07 \frac{L}{T} - 0.031 \frac{L}{B}$$

각각의 결정 계수(R<sup>2</sup>)는 0.631, 0.745, 0.711, 0.834로 계산되었다.

식 (13)과 (14)는 저속비대선과 컨테이너선의 반류계수 추정 회귀식을 보인다. 분석에 사용된 데이터의 수는 각각 약 1100개, 약 900개이다. Fig. 2, 3은 각각의 회귀 결과이다. x축은 회귀식에 의하여 추정된 값이고, y축은 모형시험 결과로 두 결과가 정확히 일치하면 모든 점이 대각선 상에 위치하게 된다.

$$w_m = 0.509 - \left(0.001LCB + 0.001 \frac{L}{B}\right) \cdot \frac{1}{Fn} - 0.178P/D + 0.048A_E/A_0 - 1.174 \frac{D_p}{B} - 0.176 \frac{D_p \cdot Fn}{T} + 0.281Cb \quad (13)$$

$$w_m = 0.068 - 0.025 \frac{L}{B} Fn - 0.001 \frac{LCB}{Fn} + 0.176 \frac{D_p}{T} + 0.277Cb + 0.055A_E/A_0 + 0.036 \frac{B}{T} - 0.01 \frac{L}{T} \quad (14)$$

각각의 결정 계수는 0.591, 0.461로 계산되었다.

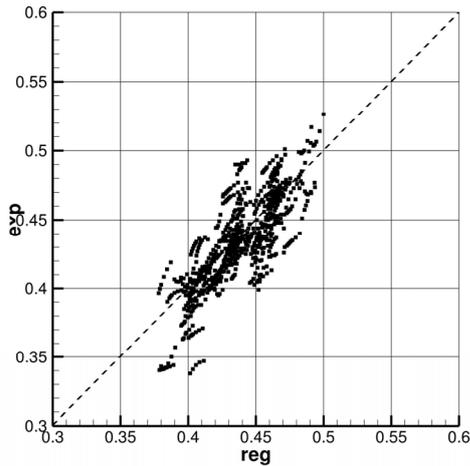


Fig. 2 w<sub>m</sub> regression result of full ships using linear regression

식 (15)와 (16)은 도출된 저속비대선과 컨테이너선의 추력감소 계수 추정 회귀식이다. 앞서 언급한 바와 같이 추력감소 계수의 경우는 속도의 영향을 고려하지 않고, 하나의 선형-프로펠러 조합의 속도별 값을 평균하여 대표 값으로 가정하고 분석을 수행하였다. 사용된 데이터의 수는 각각 약 120개이다. 계산된 결정 계수는 저속비대선의 경우 0.105, 컨테이너선의 경우 0.380으로 좋지 않은 결과를 보이고 있다. 특히 저속비대선의 경우는 전체 케이스에 대하여 평균값 하나를 사용하는 것에 비해 조금 향상된 정도에 불과하다. Fig. 4, 5는 그 결과를 보인다.

$$t = 0.129 - 0.058P/D + 0.15Cb \quad (15)$$

$$t = 0.133 + 0.12 \frac{D_p}{T} + 0.367 \frac{D_p}{B} - 0.02 \frac{L}{\nabla^{1/3}} \quad (16)$$

독립 변수로 사용된 주요 제원의 평균값 및 표준 편차는 Table 1과 같으며, 이를 많이 벗어난 선형에 대해서는 회귀식 사용에 주의가 필요하다.

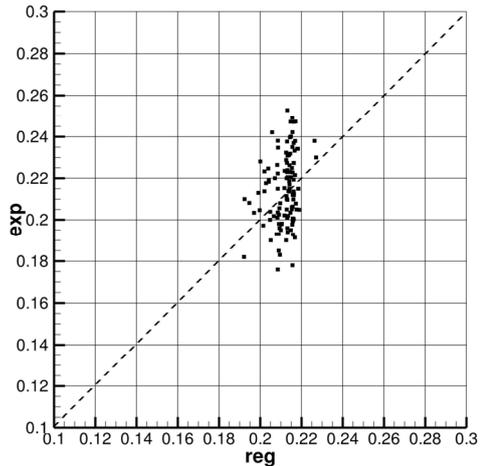


Fig. 4 t regression result of full ships using linear regression

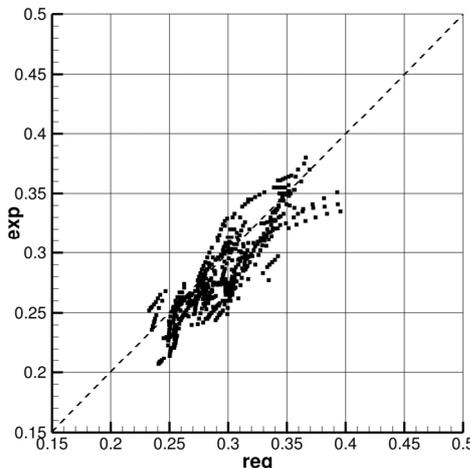


Fig. 3 w<sub>m</sub> regression result of container carriers using linear regression

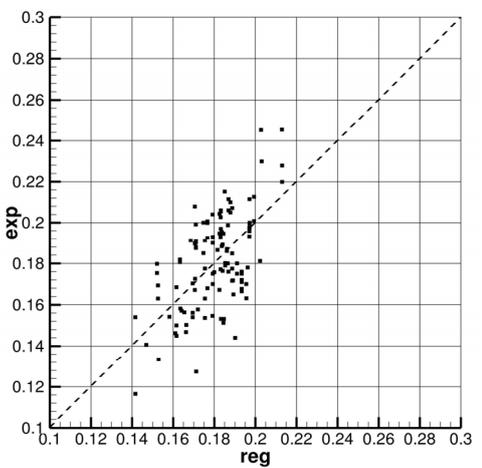


Fig. 5 t regression result of container carriers using linear regression

Table 1 Distribution of the independent variables

|                  | Full ship |       | Container |       |
|------------------|-----------|-------|-----------|-------|
|                  | mean      | stdev | mean      | stdev |
| L/B              | 6.053     | 0.374 | 6.703     | 0.754 |
| L/T              | 17.544    | 1.377 | 21.278    | 2.658 |
| B/T              | 2.908     | 0.284 | 3.187     | 0.344 |
| $L/\nabla^{1/3}$ | 5.018     | 0.169 | 6.033     | 0.451 |
| Cb               | 0.838     | 0.025 | 0.647     | 0.033 |
| LCB              | 2.690     | 0.975 | -1.113    | 0.934 |
| P/D              | 0.746     | 0.078 | 0.986     | 0.088 |
| $A_E/A_0$        | 0.512     | 0.061 | 0.723     | 0.154 |
| $D_p/B$          | 0.192     | 0.016 | 0.224     | 0.023 |
| $D_p/T$          | 0.561     | 0.070 | 0.705     | 0.032 |

### 3.2 기계 학습에 의한 성능 계수 추정

기계 학습 모델을 도출하는 방법은 Kim et al. (2020)의 방법을 참고하였다. 총 5개의 기계학습 모델(릿지 회귀, 서포트 벡터 머신, 랜덤 포레스트, 그레디언트 부스트, 신경망 모델)을 고려하였으며 (www.scikit-learn.org), 최종 모델로서 각 모델들에 가중치를 주어 결합하는 앙상블(ensemble) 모델의 하나인 보팅 회귀 모델(voting regressor)을 사용하였다(Fig. 6). 선형 회귀식 도출과는 달리 각 선종에서 Cb를 기준으로 분석 구간을 특별히 나누지 않고 회귀 분석을 실시하였으며, 입력 변수는 평균이 0이며, 분산이 1이 되도록 표준화(standard scaler)하여 분석에 사용하였다.

언어진 회귀 모델이 훈련 데이터에 과대적합 되는 가능성을 낮추기 위하여 홀드아웃 교차 검증(holdout cross-validation)과 훈련 세트와 검증 세트의 선택에 따른 민감성을 완화하기 위한 k-겹 교차 검증(k-fold cross validation) 기법을 적용하였다 (Raschka and Mirjalili, 2019). 기계 학습 회귀 모델은 각각 모델의 학습 및 예측 결과를 결정하는 파라미터들이 존재하며, 분석 데이터에 적합한 파라미터를 결정하는 것은 매우 중요하다(hyper parameter tuning). 본 연구에서는 Table 2와 같이 각 모델의 파라미터에 대한 적합한 조합을 찾는 과정을 수행하여 최종 모델을

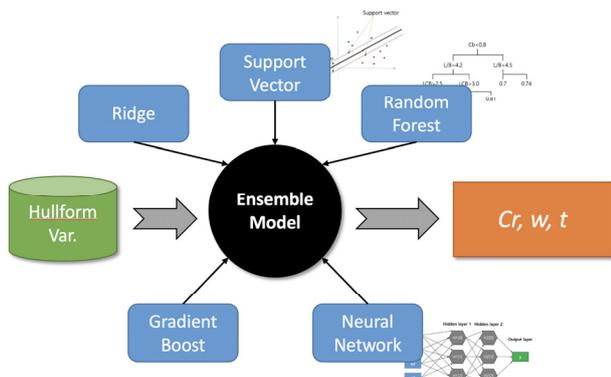


Fig. 6 Voting regressor for predicting Cr, w, and t

결정하였다. 일정 범위 내에서 변하는 파라미터를 적용한 검증 점수가 가장 높은 파라미터를 모델의 최종 파라미터로 선정하는 방식을 이용하였으며, Fig. 7은 Cr 예측 모델로서 서포트 벡터 머신의 파라미터 별 검증 점수 예를 보인다. 보팅 회귀 모델의 경우는 각각 모델의 검증 점수의 순위를 고려하여 가중치를 결정하였다.

Fig. 8과 9는 기계 학습 모델로 예측한 저속비대선과 컨테이너선의 잉여저항계수 결과를 보인다. 이 결과에는 80%의 훈련 데이터와 20%의 검증 데이터에 대한 결과가 포함되어 있다.

Table 2 Hyper-parameters for machine learning models

| Model                  | Parameters                             |
|------------------------|--|
| Ridge                  | L2 regularization                      |
| Support vector machine | C, gamma                               |
| Random forest          | No. of estimators, minimum sample leaf |
| Gradient boost         | No. of estimators, minimum sample leaf |
| Neural network         | hidden layer units, L2 regularization  |
| Voting regressor       | weight of each model                   |

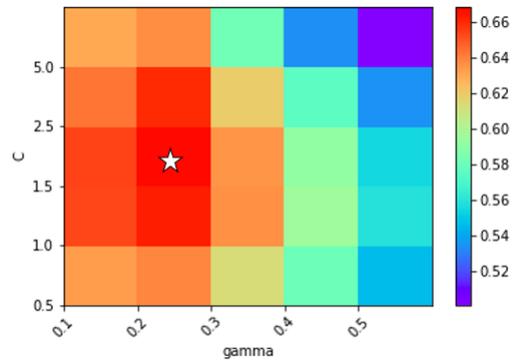


Fig. 7 Hyper-parameter tuning of support vector machine for Cr prediction

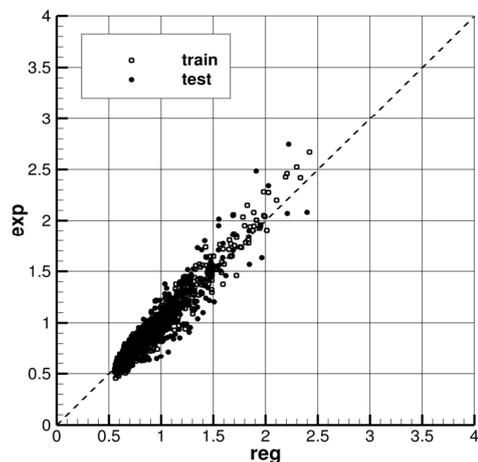


Fig. 8 Cr prediction using voting regressor for full ships

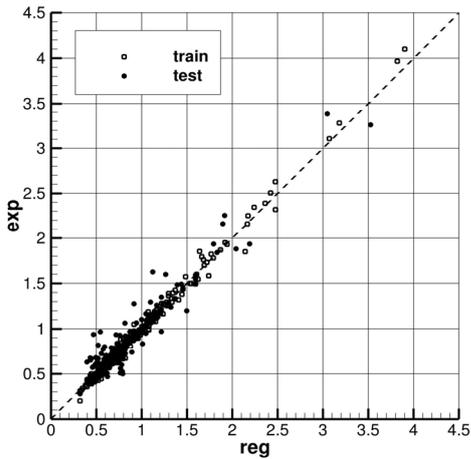


Fig. 9 Cr prediction using voting regressor for container carriers

결정계수는 각각 0.889, 0.960으로 계산되었는데, 모델 도출에 전혀 사용되지 않은 20%의 선형에 대한 결과가 포함되어 있음에도 불구하고 선형 회귀식의 결과에 비해 향상된 예측을 보인다.

Fig. 10과 11은 기계학습 모델로 예측한 모형선의 반류계수 결과를 보인다. 저속비대선의 경우, 훈련 데이터에 대한 결정계수는 0.885, 검증 데이터에 대한 결정계수가 0.646으로 계산되었으며, 선형 회귀식 결과보다 향상된 결과를 보인다. 컨테이너선의 경우, 훈련 데이터의 결정계수가 0.968, 검증 데이터의 결정계수가 0.646의 결과를 보이며, 약간의 과적합 경향이 관찰되고 있으나 선형 회귀식 결과에 비해 역시 향상된 예측을 보이고 있다.

Fig. 12, 13은 저속비대선과 컨테이너선에 대한 추력감소 계수 예측 결과를 보인다. 추력감소 계수의 경우 훈련 데이터에 대한 예측도는 상당히 높지만, 검증 데이터에 대한 결과는 잉여저항계수 및 반류계수에 비해 좋지 않다. 이는 선형 회귀식의 결과와 유사한 경향이다. 본 연구에 사용된 주요제원 만으로의 변별력이 충분하지 않음을 간접적으로 보이는 결과로 생각된다. 저속비대선의 경우, 훈련 데이터에 대한 결정계수가 0.842, 검증

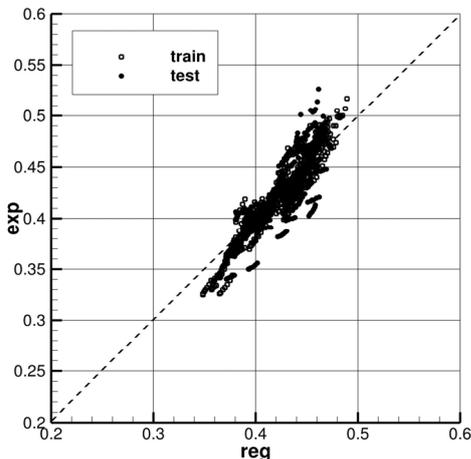


Fig. 10  $w_m$  prediction using voting regressor for full ships

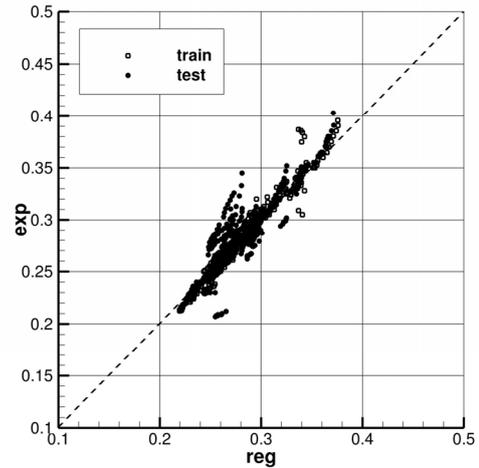


Fig. 11  $w_m$  prediction using voting regressor for container carriers

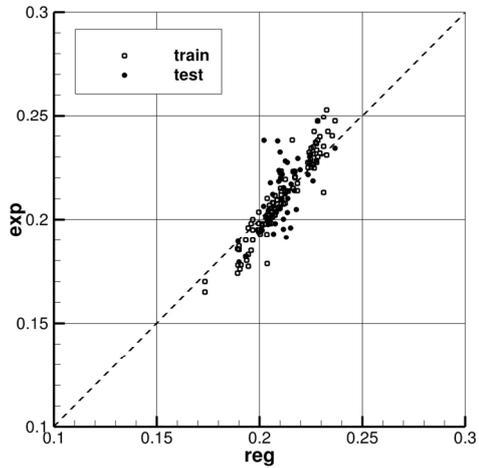


Fig. 12 t prediction using voting regressor for full ships

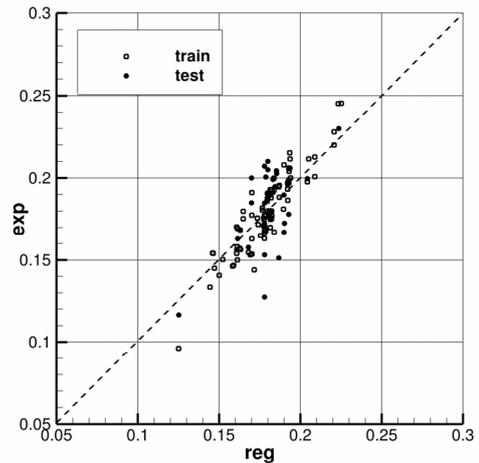


Fig. 13 t prediction using voting regressor for container carriers

데이터에 대한 결정계수가 0.364로 계산되었으며, 컨테이너선의 경우 각각 0.802, 0.404로 계산되었다. 기계학습 모델의 과적합 경향에도 불구하고, 선형 회귀식의 결과대비 검증 데이터의 결정계수도 향상된 것을 확인할 수 있다.

### 4. 회귀를 이용한 실선 마력의 추정

3장에서 보인 선형 회귀식 및 기계학습 모델을 이용하여 예측된 잉여저항계수, 반류계수, 추력감소 계수를 2장에서 보인 실선 마력 추정 방법에 적용하면 선박의 주요제원으로 실선의 제동 동력을 예측하는 것이 가능하다.

Fig. 14, 15는 저속비대선에 대한 제동 동력을 선형 회귀식과 기계학습 모델을 활용하여 예측한 결과를 모형 시험 결과로부터 추정된 실선의 제동 동력을 비교한 그림이다. 전체적으로 기계학습 기법을 이용하여 예측한 결과가 모형 시험 결과로 추정된 값에 더 가까운 값을 주는 것을 확인할 수 있다. 절대 오차의 평균(MAE; Mean Absolute Error %)은 선형 회귀식으로 예측한 결과가 7.48%, 기계학습 기법에 의한 결과가 5.67%로 나타났다.

Fig. 16과 17은 컨테이너선에 적용한 결과를 보인다. 저속비대선의 결과와 유사하게 기계학습 기법에 의한 예측 결과가 모형

시험 결과에 의한 예측치에 근접한 모습을 보이고 있다. 이는 잉여저항계수, 반류계수, 추력감소 계수 각각의 예측 결과가 기계학습 기법에서 더 좋은 일치를 보인 것의 영향으로 판단된다. 절대 오차의 평균은 선형 회귀식의 경우 6.11%, 기계학습 기법의 경우 4.25%로 계산되어, 저속비대선의 경우보다 다소 낮은 오차를 보였다.

Fig. 18은 저속비대선 중 훈련에 사용되지 않은 몇몇 선형(선형 회귀식 도출에는 사용됨)에 대하여 본 연구의 방법을 적용하여 마력 곡선을 구하고, 상용출력(NCR; Normal Continuous Rating)에서의 속력을 예측한 결과를 모형 시험 결과로부터 예측된 속력과 비교한 것이다. 실선이 회귀를 이용해서 계산된 제동 동력과 프로펠러 회전수 곡선, 점선이 모형 시험으로부터 계산된 제동 동력과 회전수를 나타낸다. A 선형은 LBP 240미터 급, B 선형은 300미터 급 선형에 대한 결과이다. 상용출력에 해당하는 속력 예측값은 두 선형 모두 모형 시험에 의한 예측값과 오차를 3% 이내의 결과를 보여주고 있다.

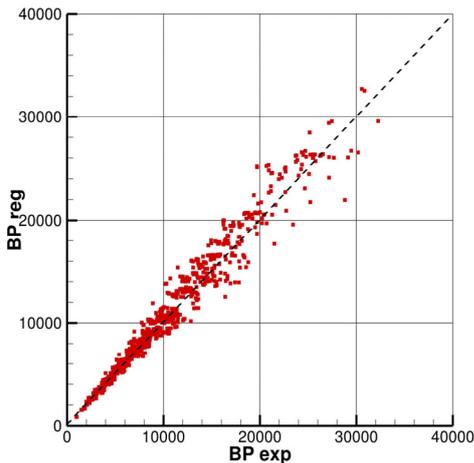


Fig. 14 Brake power prediction using linear regression for full ships

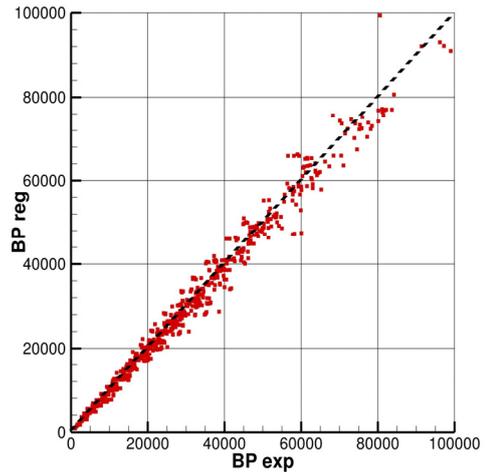


Fig. 16 Brake power prediction using linear regression for container carriers

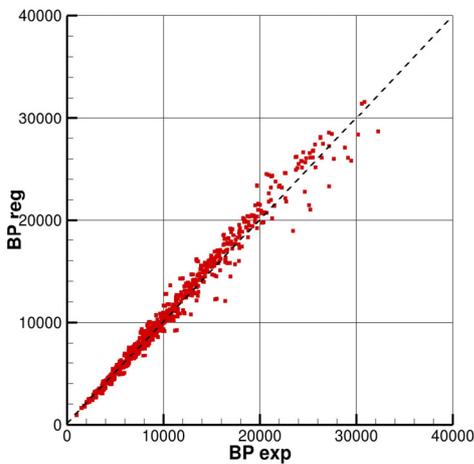


Fig. 15 Brake power prediction using voting regressor for full ships

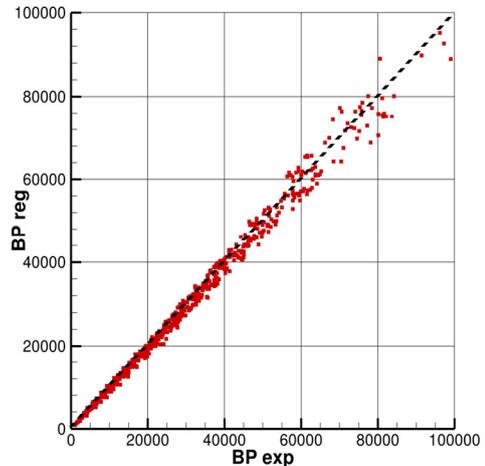
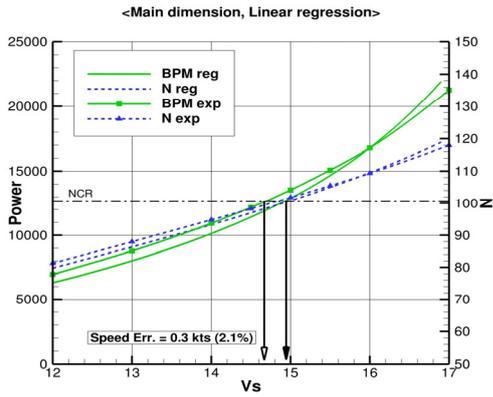
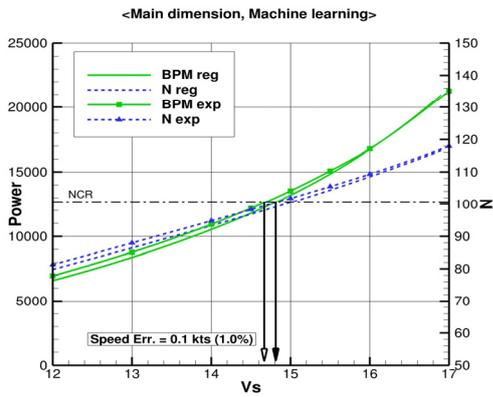


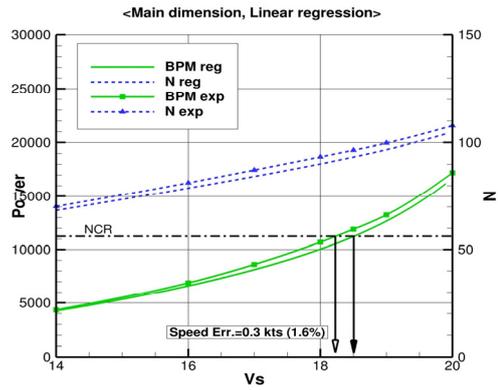
Fig. 17 Brake power prediction using voting regressor for container carriers



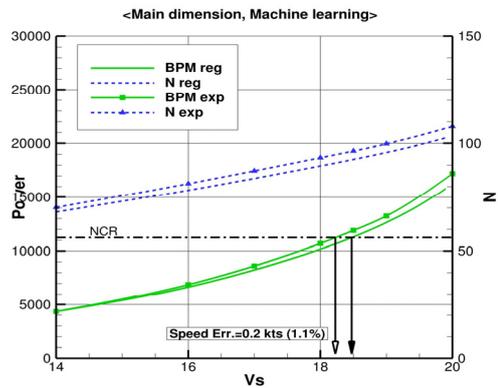
LBP ~ 240m (hull A), linear regression



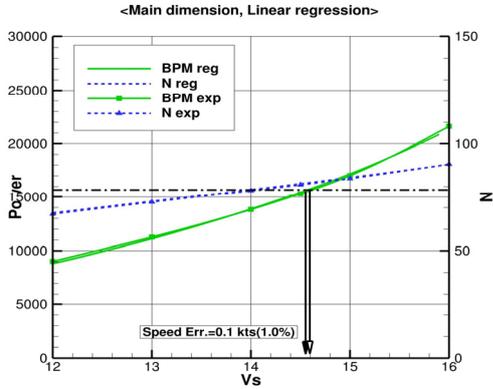
LBP ~ 240m (hull A), machine learning



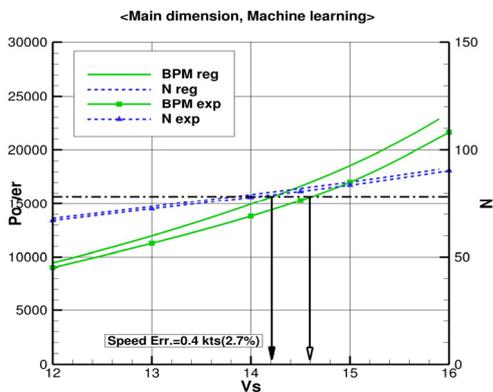
LBP ~ 160m (hull C), linear regression



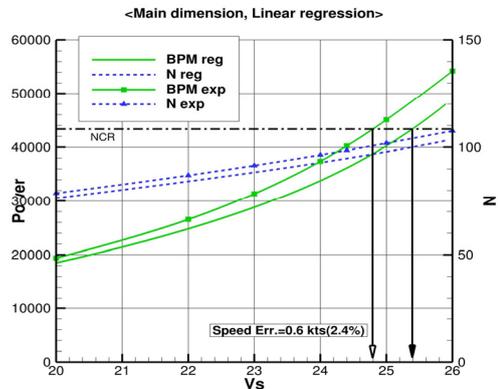
LBP ~ 160m (hull C), machine learning



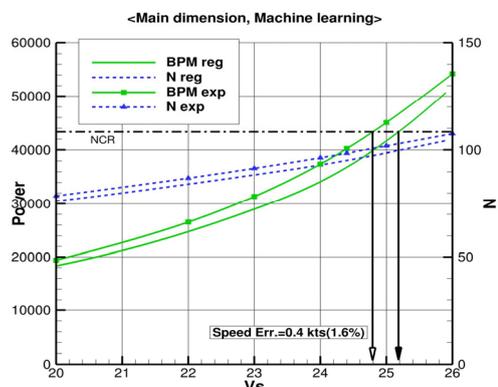
LBP ~ 300m (hull B), linear regression



LBP ~ 300m (hull B), machine learning



LBP ~ 260m (hull D), linear regression



LBP ~ 260m (hull D), machine learning

Fig. 18 Power and speed prediction results for the sample full ships

Fig. 19 Power and speed prediction results for the sample container carriers

Fig. 19는 컨테이너선 중 훈련에 사용되지 않은 선형에 대하여 결과를 비교한 것이다. C 선형은 LBP 160미터 급, D 선형은 260미터 급 선형에 대한 결과이다. 두 선형의 속력 예측값은 저속비대선의 경우와 마찬가지로 모형 시험에 의한 예측값과 오차를 3% 이내의 결과를 보여주고 있다.

### 4. 결론

선박해양플랜트연구소(KRISO)의 모형시험 결과 및 선형 정보를 활용하여 선박의 초기 설계 시 사용할 수 있는 저속비대선 및 컨테이너선의 잉여저항계수, 반류계수, 추력감소 계수에 대한 추정식을 도출하였다. 또한 기계학습 모델을 적용한 회귀 모델을 도출하고 선형 회귀식의 결과와 비교를 수행하였다. 제동 동력 산출을 위한 프로펠러 단독 성능은 B-시리즈의 것을 보정하여 사용하였으며, 상대회전 효율과 전달효율은 상수값을 사용하여 일관되게 적용하였다.

잉여저항계수, 반류계수, 추력감소 계수의 추정에 있어서 기계학습 모델이 선형 회귀식에 비해 모형시험 결과에 가까운 예측치를 주는 것을 확인하였다. 제동 동력에 대한 예측치는 약 4~7% 정도의 평균 오차율을 보였으며, 컨테이너선에 대한 결과가 저속비대선에 비해 약간 낮은 오차율을 보였다. 상용 출력에 대한 선속 예측을 4척의 샘플 선형에 대하여 수행하고 비교한 결과, 대체적으로 기계 학습 기법이 더 좋은 예측치를 보였으나, 일부 선형에서는 반대의 경우도 나타났다. 선속 오차는 모두 3% 이하의 결과를 보였다. 나선(bare hull) 상태 선형의 초기 설계 단계의 동력 추정 시 활용할 수 있는 수준으로 판단된다.

주요제원은 선박의 대략적인 형상을 대표하는 변수로서 국부의 형상까지 반영하지 못한다. 따라서 본 연구에서 제안하는 회귀식 및 회귀 모델은 주요제원이 같은 경우에 대하여 동일한 예측치를 제공할 수밖에 없는 한계가 있으며, 통계 분석에 의한 예측 모델이기 때문에 분석에 사용된 선형들과 차이가 큰 선형들에 대해서는 그 사용에 주의가 필요하다. 나아가 선형 오프셋 학습을 적용하면 국부 형상에 대한 고려가 가능하여 통계적인 선형 성능 예측 방법의 활용도를 높일 수 있을 것으로 기대된다.

### 후 기

본 논문은 선박해양플랜트연구소 주요사업 “극한환경상태의 선박성능 평가기술 개발”로 수행된 결과입니다. (PES3910)

### References

Carlton, J., 2007. *Marine propellers and propulsion*. 2nd Ed. Butterworth-Heinemann.

Holtrop, J., 1984. A statistical re-analysis of resistance and propulsion data. *International Shipbuilding Progress*, 31, pp.272-276.

Holtrop, J. & Mennen, G.G.J., 1978. A statistical power prediction method. *International Shipbuilding Progress*, 25, pp.253.

Holtrop, J. & Mennen, G.G.J., 1982. An approximate power prediction method. *International Shipbuilding Progress*, 29, pp.166-170.

ITTC, 2017. 1978 ITTC performance prediction method (revision 04). ITTC-Recommended Procedures and Guidelines, 7.5-02 03-01.4, pp.1-15.

Kim, Y.C. et al., 2019. Prediction of residual resistance coefficient of low-speed full ships using hull form variables and model test results. *Journal of the Society of Naval Architects of Korea*, 56(5), pp.448-457.

Kim, Y.C. et al., 2020. Prediction of residual resistance coefficient of low-speed full ships using hull form variables and machine learning approaches. *Journal of the Society of Naval Architects of Korea*, 57(6), pp.311-321.

Raschka, S., & Mirjalili, V., 2019. *Python machine learning*. 2nd Ed. Gilbut Publishing co., Ltd. www.scikit-learn.org

