



지도학습을 이용한 전기추진 스마트 선박의 분당회전수 및 축 동력 추정 연구

김수빈¹·유영준^{1,2,†}·강민우¹·정성준³
울산대학교 일반대학원 조선및해양공학과¹
울산대학교 공과대학 조선해양공학부²
한국해양과학기술원 부설 선박해양플랜트연구소³

Prediction of RPM and Shaft Power of an Electric-Propulsion Smart Ship from Data-Driven Analysis Using Supervised Learning

Subin Kim¹·Youngjun You^{1,2,†}·Minwoo Kang¹·Sungjun Jung³
Naval Architecture and Ocean Engineering, Graduate School, University of Ulsan¹
School of Naval Architecture and Ocean Engineering, University of Ulsan²
Korea Research Institute of Ships & Ocean engineering (KRISO)³

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.

IMO has been progressively strengthening regulations aimed at reducing greenhouse gas emissions and improving energy efficiency. As a result, there is a growing demand for methods that can quantitatively evaluate the full-scale performance of ships. Although various approaches have been proposed for estimating the performance, there are limitations in determining the relationships between speed-RPM and speed-power. Moreover, it is necessary to assess the effects of various factors on full-scale performance. In this paper, it is aimed to predict RPM and shaft power of an electric-propulsion smart ship from data-driven analysis using supervised learning. First, post-processing procedure for full-scale measurements is revised to improve the feasibility of deriving speed-RPM and speed-power relationships from the proposed model. Second, design variables for analyzing full-scale measurements based on supervised learning are established. Finally, it is possible to predict RPM and power with improved accuracy.

Keywords : Electric-propulsion smart ship(전기추진 스마트 선박), Data-driven Analysis(데이터 기반 분석), Full-scale performance (실선 운항 성능), Supervised learning(지도학습)

1. 서론

최근 국제해사기구(IMO)에서는 온실가스 배출 저감과 에너지 효율 향상을 위한 규제를 단계적으로 강화하고 있다 (Aldous et al., 2015). 이에 따라 선박의 운항 효율성을 정량적으로 평가하고, 장기 운항에 따른 성능 변화를 예측할 수 있는 분석 기법의 필요성이 높아지고 있다. 특히, 실선 운항데이터를 활용하여 운항 성능 평가 기법을 개발, 검증하고, 환경 하중 및 선체 오손 상태 변화를 반영하는 예측 기법은 연료 및 탄소배출 저감 전략 수립에 중요한 역할을 한다 (Xie et al., 2023)

실선 운항 성능을 평가하는데, 모형시험, 시운전, 수치해석 등을 기반으로 실선 운항 성능을 추정하거나, 단기간의 실선 계측

데이터를 이용하여 속도-분당회전수 및 속도-동력 관계를 추정하는 방법이 제안된 바 있다 (Terziev et al., 2021). You et al. (2017)은 수학모형을 기반으로 실선에서 계측된 바람, 파랑 정보를 고려한 실선 운항 성능과 유럽중기예보센터(ECMMF) 데이터 베이스를 통해 추정된 바람, 파랑 정보를 고려한 실선 운항 성능을 정량적으로 비교, 분석한 바 있다. Demirel et al. (2019)은 오손 조건에 따라 마찰 저항의 증가를 수치화하는 다이어그램을 제시한 바 있으며, Song et al. (2019)은 전산유체역학(CFD)을 통해 오손이 선체 저항 및 추진기 후류에 미치는 영향을 검토한 바 있다. You et al. (2020)은 실선 운항데이터에서 도출된 수리 주기에 따른 속도 손실, 오손 효과(fouling effect)로 인한 저항 증가율, 연료 소모량의 증가를 추정, 분석한 바 있다. 이처럼, 오손 효

과는 해양 부착생물의 증식에 따른 선저 표면 거칠기 증가, 추진 효율 저하, 동력 증가, 연료 소모량 증가와 같은 경제적 손실로 이어짐을 분석한 바 있다 (Torii and Kifune, 2023). Huang et al. (2022)은 지도학습 기법을 적용하여 실선 운항데이터 분석함으로써, 운항 속도와 연료 소모량의 관계성을 추정하였다. 또한, DeKeyser et al. (2022)은 신경망 기반 지도학습 모델을 실선 운항데이터 분석에 적용, 속도-동력 관계성 추정 정확도를 향상한 바 있다. 선박의 실선 운항 성능 추정을 위한 다양한 기법들이 소개되었으나, 여전히 실선 운항 성능 관점에서 속도-분당회전수, 속도-동력의 관계성을 정도 높게 추정하는데 한계가 있음을 확인할 수 있었다. 특히, 끊임없이 변화하는 바람, 파도, 또는 조류 같은 환경 하중과 진수 후, 또는 선저 청소 후 장기 운항에 따라 발생하는 오손 효과를 정량적으로 평가할 수 있는 방법론 개발의 필요성을 인지했다.

본 연구에서는 지도학습을 기반으로 2,700톤급 전기추진 스마트 선박의 실선 운항데이터를 분석함으로써, 대상 선박의 분당회전수 및 축 동력 추정 방법론을 구축하는 것을 목표로 하였다. 또한, 오손 효과가 선박의 실선 운항 성능에 미치는 영향을 정량적으로 검토하고자 했다. 첫째, 유럽중기예보센터 데이터베이스로부터 획득한 바람 정보를 실선에서 계측된 바람 정보와 정량적으로 비교 함으로써, 실선 운항 성능 분석의 타당성을 검토하였다. 둘째, 이전 연구에서 제시했던 실선 운항데이터 후처리 기법의 수정, 보완을 통해, 실선 운항데이터 분석의 타당성을 높일 방안을 제시하였다. 셋째, 실선 운항 성능 추정에 관한 선행 연구를 검토한 후, 지도학습을 적용한 실선 운항데이터 분석 모델의 설계 변수를 제안하였다. 또한, 제안된 설계변수를 이용하여, 지도 학습 기반 실선 운항데이터 분석을 수행하였다. 특히, 오손 효과가 동력 증가에 미치는 영향을 정량적으로 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 대상 선박, 기상 데이터베이스 활용 및 검증, 데이터 후처리 기법의 수정, 보완에 관하여 기술하였다. 3장에서는 실선 운항데이터 분석에 적용한 지도 학습 기법을 설명하고, 지도학습을 위해 작성한 설계변수 및 학습 조건에 대하여 정리하였다. 4장에서는 설계된 학습 조건에 따라 지도학습을 적용, 도출한 속도-분당회전수, 속도-축 동력 관계성을 분석하였다. 또한, 오손 효과가 동력 증가에 미치는 영향을 분석하였다. 5장에서는 본 연구에서 검토한 사항을 요약, 정리하였다.

2. 대상 선박 및 실선 운항데이터 후처리

2.1 대상 선박

본 연구의 대상 선박은 2,700톤급 직류 기반 하이브리드 전기 추진 스마트 선박으로, 2022년에 진수되었다. Fig. 1에서 보여주고 있는 대상 선박에는 실시간 상태 모니터링 시스템이 탑재되어 있어, 운동 정보(시각, 경위도, 선속, 선수각, 침로 등)와 기상 상태(상대 풍속, 상대 풍향, 분당회전수, 축 동력 등을 계측할 수



Fig. 1 2,700ton-class electric propulsion smart ship (ULSAN TAEHWA)

Table 1 Principal dimensions of 2,700ton-class electric propulsion smart ship (ULSAN TAEHWA)

Property		Value
Lpp [m]		78.5
Breadth [m]		12.8
Design draft [m]		3.3
Gross tonnage [mt]		2,696
Speed	Design [knots]	14
	Maximum [knots]	16
Number of propellers [EA]		2
Number of propeller blades [EA]		4
Predicted shaft power at design speed with design draft [kW]		1,150

있다. 최근에는 파도 레이더를 추가 탑재하여, 파랑 정보 (유의파고, 평균 파주기, 파향)까지 계측할 수 있는 것으로 알려져 있다. 울산정보산업진흥원(UIPA)에서는 대상 선박이 운용된 이래 계측, 저장된 실선 운항데이터를 활용, 데이터 비즈니스를 추진하고 있다. 울산태화호의 실선 운항데이터를 지속적으로 계측, 축적하고 있기 때문에, 오손 효과가 실선 운항 성능에 미치는 영향을 추적, 조사하는 데 적합하다 (Gupta et al., 2022). 대상 선박의 주요 제원은 Table 1에서 보여주고 있으며, 설계 속도는 14knots, 설계 속도 기준 축 동력은 약 1,150kW 이다 (KRISO, 2021).

2.2 기상 데이터베이스 활용 및 검증

본 연구에서는 2023년 1월 5일 09시 30분(KST)부터 2024년 2월 29일 15시 57분(KST)까지 울산태화호에서 1분 간격으로 계측된 실선 운항데이터를 분석에 활용하였다. 실제 획득한 데이터는 2024년 7월 18일 15시 34분(KST)까지 였으나, 2024년 3월 12일에 선저 청소가 있었음을 확인한 바 있기 때문에 (Kang et al., 2025), 지도학습을 적용한 실선 운항데이터 분석을 위해 선저 청소 이후의 계측 데이터는 분석에서 제외하였다. 경위도, 대지속도(SOG), 분당회전수, 축 동력을 포함하여 상대 풍속, 상대

풍향이 포함되어 있다. 선행 연구와 같이 유럽중기예보센터 ERA5 데이터베이스를 이용하여, 시각 및 경위도에 따른 바람 정보(u_{10} , v_{10}), 파랑 정보(유의파고, 평균 파주기, 파향) 등의 정보를 획득할 수 있었다. 단, 바람 정보는 0.25° 간격, 파랑 정보는 0.5° 간격의 공간 해상도를 가지며, 공통적으로 1시간 간격의 시간 해상도를 갖는다. 여기서, u_{10} 은 동서 방향의 바람 속도 성분, v_{10} 은 남북 방향의 바람 속도 성분을 가리킨다.

앞서, 본 연구에서 활용된 실선 운항데이터에는 실선에서 계측한 상대 풍속, 상대 풍향 정보가 포함되어 있음을 밝힌 바 있다. 지도학습을 적용한 실선 운항데이터 분석 시, 바람 및 파랑 정보가 이용되었기 때문에, 추정된 정보의 타당성을 확인할 필요가 있었다. 기상 데이터베이스에서는 진북 기준으로 도출된 u_{10} , v_{10} 값을 제공하기 때문에, 선박의 운동 정보를 고려하여, 상대 풍속, 상대 풍향으로 변환한 후 비교할 필요가 있었다 (You et al., 2017).

먼저, 본 연구에서 대상 선박의 운동 정보, 바람 및 파랑 정보의 축계 정의는 Fig. 2와 같다. 식 (1)에서는 지구고정좌표계를 기준으로 절대 풍속을 계산하고 있으며, 식 (2)에서는 u_{10} , v_{10} 으로부터 진북을 기준으로 절대 풍향을 계산하고 있다. 식 (3), (4)에서는 절대 풍속, 절대 풍향과 대상 선박의 운동 정보를 고려하여, 상대 풍속, 상대 풍향을 계산하고 있다. 단, 실선 운항데이터에서 대상 선박 u , v 정보를 각각 제공하지 않는다. 실선 운항데이터 편류각의 평균값은 0.283° 였고, 중앙값은 -0.05° 였다. 편류각의 크기가 매우 작다고 판단하여, 편류각을 0으로 가정하였다. 따라서, u 가 U 와 같고, v 는 0이라고 가정하였다.




Fig. 2 Coordinates

$$V_{WI} = \sqrt{u_{10}^2 + v_{10}^2} \tag{1}$$

$$\psi_{WI} = \text{atan2}(v_{10}, u_{10}) + \pi \tag{2}$$

$$u_{RW} = V_{WI} \times \cos(\psi_{WI} - \psi) + u \tag{3}$$

$$= V_{WI} \times \cos(\psi_{WI} - \psi) + U \text{ (assumed)}$$

$$v_{RW} = V_{WI} \times \sin(\psi_{WI} - \psi) + v \tag{4}$$

$$= V_{WI} \times \sin(\psi_{WI} - \psi) \text{ (assumed)}$$

$$V_{RW} = \sqrt{u_{RW}^2 + v_{RW}^2} \tag{5}$$

$$\psi_{RW} = \text{atan2}(v_{RW}, u_{RW}) \tag{6}$$

식 (1)~(6)을 이용하여 변환된 상대 풍속과 상대 풍향을 비교했다. 먼저, 2023년 11월 13일 13시 13분부터 19시 12분까지 1개 항차에 해당하는 상대 풍속 시계열과 상대 풍향 시계열을 Fig. 3, 4에서 각각 보여주고 있다. 또한, 실선 운항데이터에 포함된 상대 풍속, 상대 풍향 계측값을 각각 보여주고 있다.

Fig. 3에서는 실선에서 계측된 바람의 상대 풍속의 시계열과 유럽중기예보센터 ERA5 데이터 및 대상 선박의 운동 정보로부터 변환된 상대 풍속의 시계열을 비교할 때, 3.5시간에서부터 4.5시간 범위를 제외하고는 대체로 실선에서 계측한 상대 풍속이 더 크게 나타남을 알 수 있다. 유럽중기예보센터 ERA5로부터 도출된 값은 해수면으로부터 10m 높이에서, 1시간 평균 풍속을 기준으로 추정된 값이다. 따라서, 끊임없이 변화하는 바람의 특성, 심지어 돌풍(gust)을 고려할 수 없다 (Kim et al., 2021; Taylor et al., 1994). 또한, 풍속계(anemometer)의 설치 위치에 따라 선체-센서 간 간섭도 고려할 수 없다. 따라서, 실선에서 계측한 상대 풍속이 유럽중기예보센터 ERA5 데이터 및 대상 선박의 운동 정보로부터 변환된 상대 풍속보다 크게 도출됨을 이해할 수 있다




Fig. 3 Comparison between measured relative wind speed and calculated relative wind speed considering AIS and ECMWF database

(You et al., 2017).

Fig. 3에서는 실선에서 계측된 바람의 상대 풍속의 시계열과 유럽중기예보센터 ERA5 데이터 및 대상 선박의 운동 정보로부터 변환된 상대 풍속의 시계열이 매우 유사함을 알 수 있다. 다만, Fig. 4에서 약 0.4시간, 약 5.8시간을 전후로 상대 풍향이 매우 넓게 분포하고 있다. 이 시점은 상대 풍속이 매우 작아, 대상 선박의 운동 변화 또는 바람의 속도, 방향 성분의 변화에 따라 민감하게 변화했음을 알 수 있다 (You et al., 2017).

2023년 1월 5일 09시 30분(KST)부터 2024년 2월 29일 15시 57분(KST)까지 계측된 전체 실선 운항데이터에 대해서, 상대 풍




Fig. 4 Comparison between measured relative wind incident angle and calculated relative wind incident angle considering AIS and ECMWF database

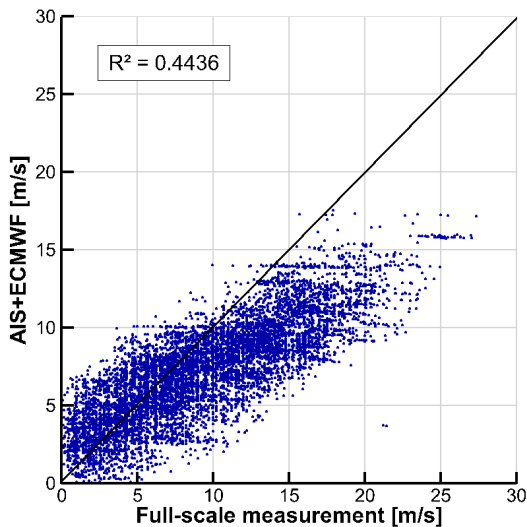


Fig. 5 Correlation analysis between measured relative wind incident speed and calculated relative wind incident speed considering AIS and ECMWF database

속과 상대 풍향을 기준으로 타당성을 분석하고자 했다. Fig. 5, 6은 실선에서 계측된 상대 풍속, 상대 풍향과 유럽중기예보센터 ERA5 데이터 및 대상 선박의 운동 정보로부터 변환된 상대 풍속, 상대 풍향의 상관 분석 결과를 보여주고 있다.

Fig. 5에서 보는 것처럼, 상대 풍속의 결정계수는 0.4436으로 매우 낮은 것으로 보인다. 다만, 계측된 상대 풍속이 변환된 상대 풍속에 비해 대체로 큰 경향성을 보이고 있으며, 상대 크기의 기울기가 일정함을 확인할 수 있다. 이것은 앞서 언급했던 것처럼, 평균 풍속, 돌풍, 선체-센서 간섭이나, 풍속계 자체의 특성 때문일 수 있다. 다만, 유럽중기예보센터 ERA5 데이터 및 대상 선박의 운동 정보로부터 변환된 상대 풍속을 이용한 실선 운항데이터 분석 시 바람 하중의 영향이 과소 평가될 수 있어, 주의가 필요하다.

Fig. 6에서 보는 것처럼, 상대 풍향의 결정계수는 0.9361로 상대적으로 매우 높은 것으로 보인다. 선행 연구들에서도 추정된 상대 풍향과 계측값 사이의 정량적 유사성을 확인한 바 있어 (Hair et al, 2010), 실선 운항데이터 분석 시 상대 풍향의 계측값과 변환값의 오차로 인한 오류 가능성은 미미할 것으로 예상된다.

파랑 정보(유의파고, 평균 파주기, 파향)에 대해서는 실선 계측 데이터에 포함되어 있지 않았기 때문에, 직접 비교를 통한 타당성 검토가 불가능했다. 다만, 선행 연구에서 유의파고는 계측값이 유럽중기예보센터 ERA5 데이터보다 크게, 상대 파향은 매우 유사하게 나타남을 확인한 바 있다 (You et al., 2017).

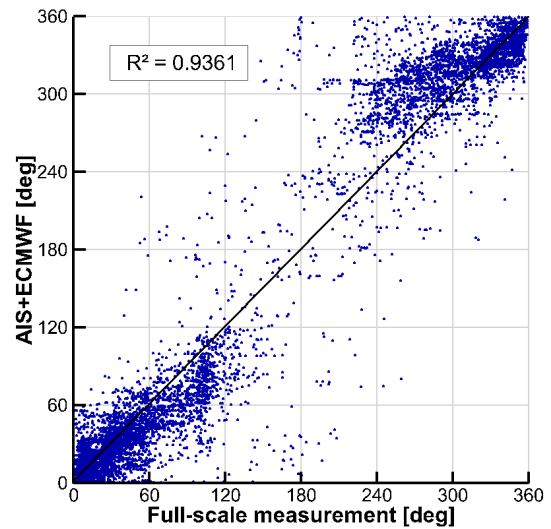


Fig. 6 Correlation analysis between measured relative wind incident angle and calculated relative wind incident angle considering AIS and ECMWF database

2.3 실선 운항데이터 후처리

선행 연구에서 실선 운항데이터 분석을 위하여, 계측값의 오차, 누락, 이상값에 대한 후처리 절차를 밝힌 바 있다 (Kang et al., 2025). 지도학습을 실선 운항데이터 분석에 적용하는 과정에서, 후처리 절차를 수정, 보완할 필요성을 인지하였다. 수정된 절

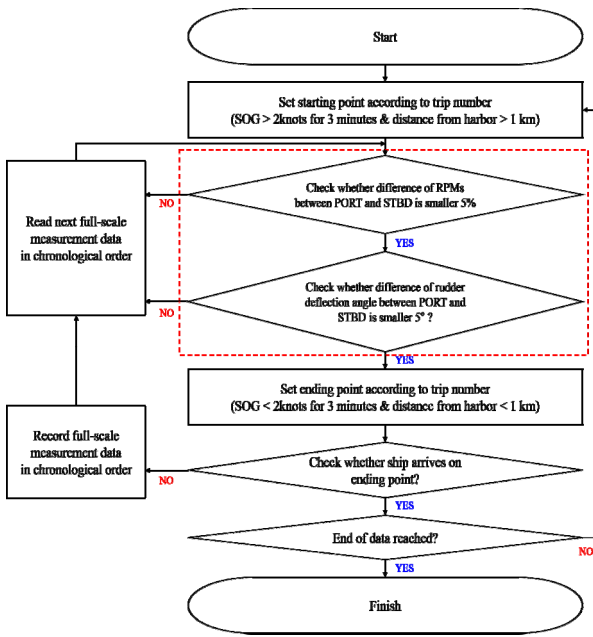


Fig. 7 Flow chart for post-processing full-scale measurement data implementing supervised learning

차는 Fig. 7과 같이 순서대로 작성하였다. 선행 연구에서는 울산 신히(35.456°N, 129.360°E) 반경 1km, 대지속도 2knots를 기준으로 항차를 구분하였다. 또한, 센서 오작동으로 인해 계측값이 0, 또는 물리적으로 불가능한 값일 경우 제외하였으며, 운항 중 3knots 이하 구간은 실선 운항데이터 분석에서 제외한 바 있다.

추가로, 지도학습을 이용해 실선 운항데이터 분석 시 대각도 변침이 수행되는 시점의 계측값을 제외할 필요성이 있었다. 선행 연구의 후처리 절차를 적용한 후, 속도-축 동력 관계성을 분석하던 중 저속(3-7knots) 구간 특정 축 동력을 기준으로 대지속도가 폭넓게 분포하는 특징을 확인하였다. Fig. 8과 같이 각각의 항적과 운항 속도를 비교, 분석한 결과, 대상 선박의 실선 운항데이터는 국내 기자재 실증, 해상 관광 등을 목적으로 연안 항해, 대각도 변침, 가감속 구간이 다수 포함되었음을 확인하였다. 통상, 선박이 대각도 변침 행위를 할 경우, 선체 측면으로 유입되는 횡방향 유속, 편류각이 증가되며, 이에 따라 선체 저항이 증가된다(Hooft, 1994). 대각도 변침 중 계측된 분당회전수 또는 동력이 유지되고 있음에도 저항 증가로 운항 속도는 감소한다. 따라서, 대각도 변침 행위 중 기록된 실선 운항데이터가 학습에 적용될 경우, 선박의 속도-분당회전수, 속도-축 동력 관계성이 왜곡될 수 있다.

Fig. 7에서 보는 것처럼, 수정된 실선 운항데이터 후처리 과정은 다음과 같다. 첫째, 경위도 좌표, 대지속도 등을 고려하여 항차 시작점을 결정한다. 둘째, 좌, 우현의 분당회전수 차이가 5% 이하인지 판단한다. Coraddu et al. (2013)가 수행했던 자유항주 모형시험에서 직진 중 좌, 우현 분당회전수의 차이는 약 2 이하였다. 평균 분당회전수 40을 기준으로 5%에 해당, 데이터 후처리 기준으로 차용하였다. 셋째, 좌, 우현 타각의 차이가 5deg 이하인지 판단한다 (Yasukawa and Yoshimura, 2015). 두 가지 조

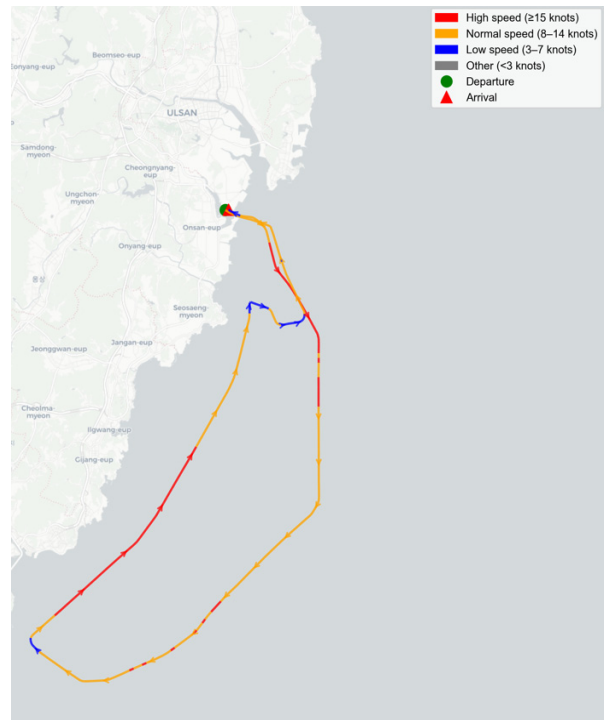


Fig. 8 An example of sea route according to speed range

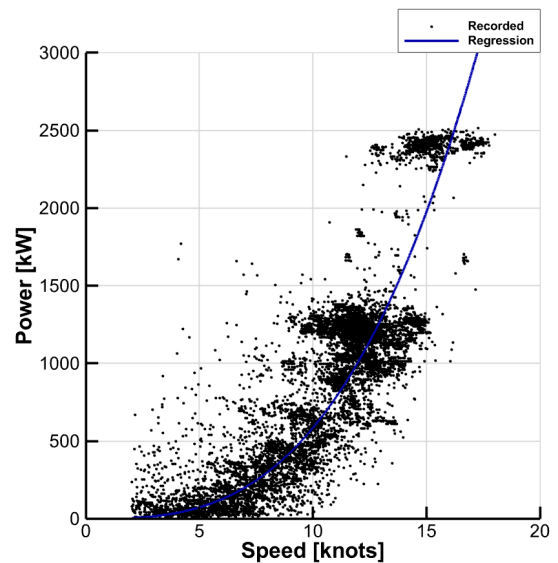


Fig. 9 Speed-power relations by plotting full-scale measurements before excluding large alternation records

건을 만족하지 않는다면, 해당 시점에 대상 선박이 대각도 변침 중인 것으로 간주하고, 1분 뒤 데이터를 검토한다. 넷째, 경위도 좌표, 대지속도 등을 고려하여 항차 도착점을 결정한다. 다섯째, 만약 항차 도착점에 도달하지 않았다면, 계속해서 해당 데이터를 발체, 저장한다. 여섯째, 해당 데이터가 전체 데이터의 마지막인지 확인한 후, 마지막이 아니라면 새로운 항차에 대해서 데이터 발체, 저장을 반복한다.

Fig. 9는 선행 연구의 실선 운항데이터 후처리 절차를 따라,




Fig. 10 Speed–power relations by plotting full-scale measurements after excluding large alternation records

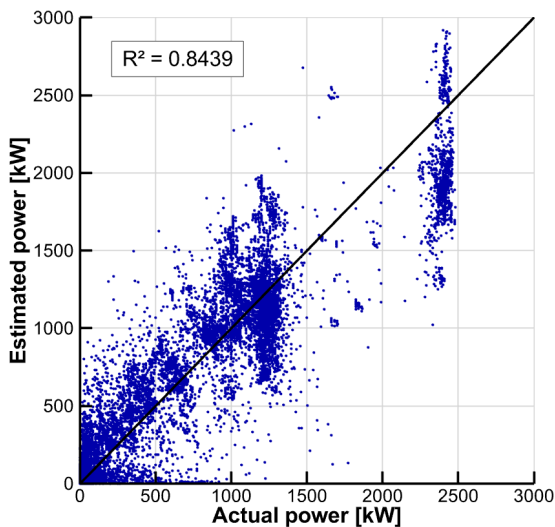


Fig. 11 Correlation analysis between actual power and estimated power obtained by regression before excluding large alternation records

대각도 변침 중 기록된 데이터가 제외되기 전, 데이터 분포 및 속도-축 동력 관계성을 보여주고 있다. Fig. 10은 대각도 변침 중 기록된 데이터가 제외된 후, 데이터 분포 및 속도-축 동력 관계성을 보여주고 있다. 10–11knots 이하 구간에서 회귀선보다 높은 쪽에 표시된 점의 수가 뚜렷하게 감소했음을 확인할 수 있다. 특히, 3–7knots 구간에서는 뚜렷하게 데이터가 감소했음을 알 수 있다. Fig. 11은 대각도 변침 중 기록된 데이터가 제외되기 전 실선 운항데이터를 이용하여, 속도-축 동력 관계에 회귀식을 적용한 것이다. 추정된 동력과 계측된 동력 간 상관 분석 결과이다. Fig. 12는 대각도 변침 데이터가 제외된 후 실선 운항데이터를 이용하여, 속도-축 동력 관계에 회귀식을 적용한 것이다. 추정된




Fig. 12 Correlation analysis between actual power and estimated power obtained by regression after excluding large alternation records

동력과 계측된 동력 간 상관 분석 결과이다. 대각도 변침 데이터를 제외하기 전후를 비교할 때, 결정계수가 0.8439에서 0.7439로 뚜렷하게 감소하였다. 저속 선회 시 기록된 많은 양의 운항데이터가 제외됨에 따라, 분석에 이용된 실선 운항데이터 중 중·고속 구간 데이터의 비율이 높아졌기 때문에 판단했다. 제외된 데이터가 학습에 미치는 악영향이 더 크기 때문에, 데이터 후처리 과정에서 결정계수의 저하는 불가피한 선택으로 판단했다. 본 연구에서 추가로 제안한 실선 운항데이터 후처리 절차를 통해, 속도-분당회전수, 속도-축 동력 관계성 추정에 왜곡을 일으킬 수 있는 오류 원인을 제거한 것으로 판단하였다.

오손 효과가 대상 선박의 동력 증가에 미치는 영향을 상대 동력 증가율($R(t)$)로 정량화하기 위하여, 식 (7)을 이용하였다 (Uzun et al. 2019). 오손 효과가 반영되기 전, 진수 시점의 축 동력값은 $P_{clean}(t)$ 로 정의하였으며, 1,150kW이다 (KRISO, 2021). 지도학습을 수행한 후, 학습 모델에서 오손 효과 작용 시간을 고려한 축 동력을 $P_{fouled}(t)$ 로 정의하였다. 여기서, t 는 진수 또는 선저 청소 후 경과한 일수를 가리킨다.

$$R(t) = \frac{P_{fouled}(t) - P_{clean}(t)}{P_{clean}(t)} \times 100 [\%] \quad (7)$$

3. 지도학습 기반 실선 운항데이터 분석 및 예측 모델 설계

3.1 지도학습 기반 예측 모델 개요

선행 연구에서 2,700톤급 전기추진 스마트 선박의 실선 운항 데이터를 최소자승법을 이용하여 속도-분당회전수, 속도-동력 관

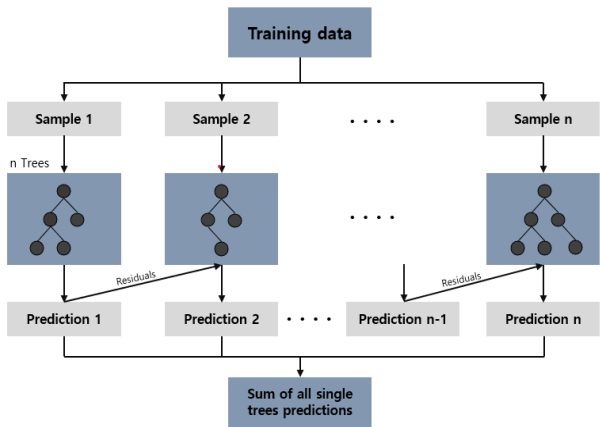


Fig. 13 Schematic diagram for supervised learning algorithm (XGBoost)

계성을 회귀 분석을 수행하였다. 분석 과정에서, 더 많은 변수를 이용한 관계성 추정의 필요성을 인지한 바 있다 (Kang et al., 2025). 선박의 운항과 관련된 더 많은 변수를 고려한 예측 모델을 설계하기 위하여, 기계학습을 기반으로 한 방법론을 적용하고자 했다. 다양한 기계학습 기법을 이용한 선박 동력 추정 결과를 비교한 결과, 지도학습 라이브러리(XGBoost)의 적용 가능성을 확인했다 (Lang et al., 2022). XGBoost의 알고리즘은 Fig. 13과 같다. 해당 라이브러리는 결정트리 구조를 기반으로 한 경사 하강 부스팅 앙상블 알고리즘으로, 시계열 데이터 간의 순서와 시점 의존성을 모델링하지 않는 특징을 가지고 있다. 예측된 실선 운항데이터가 1분 간격으로 예측되었기 때문에, 각 데이터가 독립적인 것으로 간주할 수 있다고 판단하였다. 특히 실선 운항 성능은 속도, 흘수, 분당회전수, 동력, 기상 상태 등 다수의 독립 변수에 영향을 받으며, 비선형적인 변수 간 상호작용도 존재한다 (Bassam et al., 2022).

3.2 설계 변수, 학습 및 검증 조건

You et al. (2018)은 조종운동방정식을 기반으로 한 수학모형을 이용하여 실선 운항 성능을 추정하는 방법론을 제시하면서, UTC, 경위도, 대지속도, 흘수, 풍속, 풍향, 유의파고, 평균 파주기, 파향 등을 고려한 바 있었다. 이때 추정된 분당회전수, 동력을 기준으로 추정 결과의 타당성을 분석하였다. 이를 참고하여, 지도학습 기반 예측 모델에 이용할 설계변수를 Table 2와 같이 선택하였다. 지도학습 예측 모델에서 수학모형을 반영하지는 못했으나, 실선 운항 성능 추정에 필요한 변수를 이용하여 학습 타당성을 높이고자 했다. 획득한 실선 운항데이터 중에서 학습과 검증에 이용할 데이터를 구분하기 위하여, Kennard-Stone 알고리즘을 이용하였다. 이 알고리즘은 데이터 공간에서 가장 멀리 떨어진 점들을 우선 선택한 뒤, 선택된 점들과 최대 거리를 유지하는 표본을 반복적으로 추가하는 방식으로 학습 데이터를 구성한다. 이를 통해 학습 데이터가 특정 조건에 편중되지 않도록 하여, 회귀 모델의 일반화 성능을 향상할 수 있다. 학습용 데이터

Table 2 Design variables for implementing supervised learning

Design variables	Variable	Unit	Case #1	Case #2	Case #3
Inputs	SOG	knots	○	○	○
	Drift angle	deg	X	○	○
	Mean draft	m	X	○	○
	Relative wind speed	m/s	X	○	○
	Relative wind direction	deg	X	○	○
	Significant wave height	m	X	○	○
	Mean wave period	sec	X	○	○
	Relative wave direction	deg	X	○	○
Outputs	Duration of fouling effect	day	X	X	○
	RPM	-	●	●	●
	Shaft power	kW	●	●	●

80%와 검증용 데이터 20%로 나누었으며, Kennard-Stone 알고리즘으로 학습용 데이터에 해당하는 80% 선정하면, 나머지 데이터에 해당하는 20%를 검증에 이용하였다. 지도학습을 이용한 실선 운항 성능 예측 모델의 특성을 분석하기 위하여, 모두 세 가지 설계변수 조건에서 학습을 수행하였다. 첫째, Case #1은 Kang et al. (2025)이 대지속도를 기준으로 회귀 분석을 수행했던 것처럼, 대지속도 하나의 변수만으로 학습을 수행한 것이다. 둘째, Case #2는 You et al. (2018)의 실선 운항 성능 추정 연구에서 수학모형에 이용된 대표 변수를 고려하여 학습을 수행한 것이다. 셋째, Case #3은 오손 효과가 작용한 시간을 일수로 산정한 후 Case #2의 설계변수에 추가한 것이다. 세 가지 조건 모두 분당회전수와 축 동력을 기준으로 타당성을 검토하였다. Table 2에서 대지속도, 평균흘수, 분당회전수, 축 동력은 실선 운항데이터에 기록된 값을 이용했다. 단, 편류각은 실선 운항데이터에 기록된 선수각과 침로각(COG)의 차이로 계산하였다. 유의파고, 평균 파주기는 유럽중기예보센터 ERA5 데이터에서 획득한 값이다. 또한, 상대 풍속, 상대 풍향, 상대 파향은 유럽중기예보센터 ERA5 데이터와 대상 선박의 운동 상태를 고려하여 변환한 값이다. 오손 효과 작용 시간은 진수 또는 선저 청소 이후에 경과된 일수이다 (Kang et al., 2025).

4. 지도학습을 적용한 실선 운항데이터 분석

4.1 단일 입력변수를 이용한 예측 결과

Fig. 14는 예측된 실선 운항데이터 상의 분당회전수와 단일 입




Fig. 14 Correlation analysis between actual RPM and predicted RPM by implementing supervised learning considering SOG only (Case #1)

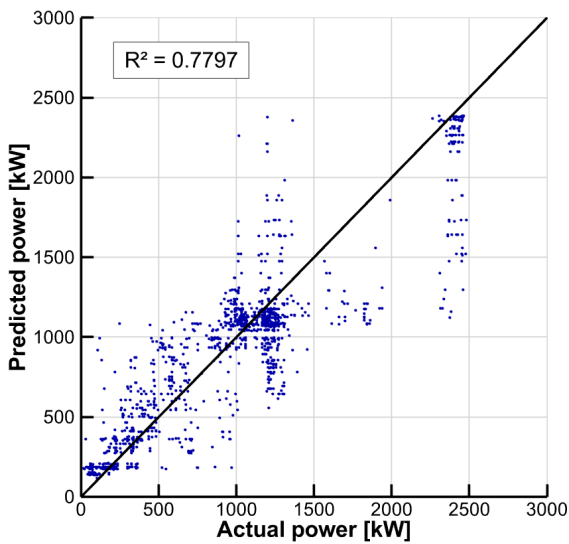


Fig. 15 Correlation analysis between actual power and predicted power by implementing supervised learning considering SOG only (Case #1)

력변수(대지속도)를 기준으로 지도학습을 적용, 추정된 분당회전수의 상관 분석 결과를 보여주고 있다. Hair et al. (2010)에 따르면, 결정계수가 0.75 이상이면 높은 예측 적합도를 보인다고 간주한다. 다만, 동일한 실선 운항데이터를 활용하여 최소자승법을 적용했던 선행 연구의 결정계수가 약 0.80이었던 것과 비교할 때, 미미한 개선 효과가 있었다.

Fig. 15는 계측된 실선 운항데이터 상의 축 동력과 단일 입력 변수(대지속도)를 기준으로 지도학습을 적용, 추정된 축 동력의 상관 분석 결과를 보여주고 있다. 동일한 실선 운항데이터를 활용하여 최소자승법을 적용했던 선행 연구의 결정계수가 약 0.73이었던 것과 비교할 때, 미미한 개선 효과가 있었다.

Fig. 14, 15에서 보는 것처럼, 속도-분당회전수 결정계수가 속도-축 동력의 결정계수보다 높은 경향성도 선행 연구의 결과와 유사함을 알 수 있다 (Kang et al., 2025). 다만, 대지속도만을 이용하는 최소자승법, 지도학습 기반 예측 결과 모두 사용자로부터 만족할 수준의 예측 결과를 보여주지는 못했다. 따라서, 실선 운항 성능에 영향을 주는 다양한 변수를 고려한 학습 모델의 적용이 필요함을 다시 한번 확인할 수 있었다.

4.2 복수 입력변수를 이용한 예측 결과

Fig. 16은 계측된 실선 운항데이터 상의 분당회전수와 선택된 복수 입력변수를 기준으로 지도학습을 적용, 추정된 분당회전수




Fig. 16 Correlation analysis between actual RPM and predicted RPM by implementing supervised learning excluding fouling effect index (Case #2)

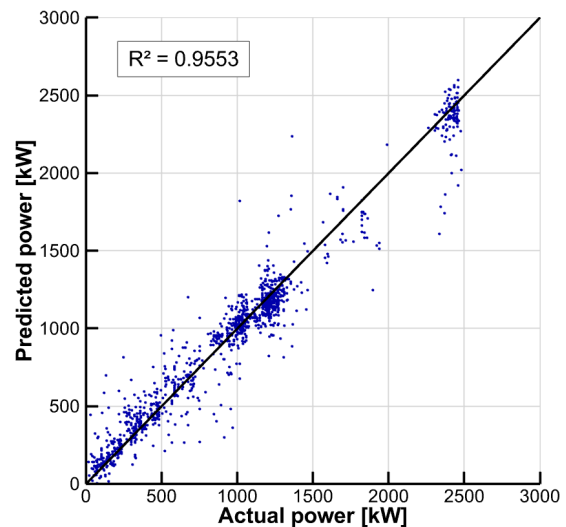


Fig. 17 Correlation analysis between actual power and predicted power by implementing supervised learning excluding fouling effect index (Case #2)

의 상관 분석 결과를 보여주고 있다. Fig. 14와 비교할 때, 결정계수가 0.8476에서 0.9633로 뚜렷하게 향상되었다.

Fig. 17은 예측된 실선 운항데이터 상의 축 동력과 선택된 복수 입력변수를 기준으로 지도학습을 적용, 추정된 축 동력의 상관 분석 결과를 보여주고 있다. Fig. 15와 비교할 때, 결정계수가 0.7797에서 0.9553로 뚜렷하게 향상되었다.

Fig. 16, 17에서 보는 것처럼, 복수의 입력변수를 기준으로 지도학습을 적용한 속도-분당회전수, 속도-축 동력의 예측 결과가 대지속도를 단일 변수로 고려한 예측 결과에 비해 뚜렷하게 향상되었다. 결정계수의 뚜렷한 향상은 선택된 설계변수가 실선 운항 성능과 밀접한 관계성을 가지고 있음을 의미한다 (Panda, 2022). 이를 통해, 실선 운항 성능 추정에 지도학습을 적용한 예측 모델을 적용할 수 있을 것으로 판단하였다.

4.3 오손 효과 작용 기간이 추가된 복수 입력변수를 이용한 예측 결과

Fig. 18은 예측된 실선 운항데이터 상의 분당회전수와 오손 효과 작용 기간이 추가된 복수 입력변수를 기준으로 지도학습을 적용, 추정된 분당회전수의 상관 분석 결과를 보여주고 있다. Fig. 16과 비교할 때, 결정계수가 0.9633에서 0.9657로 미미하게 향상되었다.

Fig. 19는 예측된 실선 운항데이터 상의 축 동력과 오손 효과 작용 기간이 추가된 복수 입력변수를 기준으로 지도학습을 적용, 추정된 축 동력의 상관 분석 결과를 보여주고 있다. Fig. 17과 비교할 때, 결정계수가 0.9553에서 0.9587로 미미하게 향상되었다.

Fig. 18, 19에서 보는 것처럼, 오손 효과 작용 기간이 추가된 복수 입력변수를 기준으로 지도학습을 적용한 속도-분당회전수,

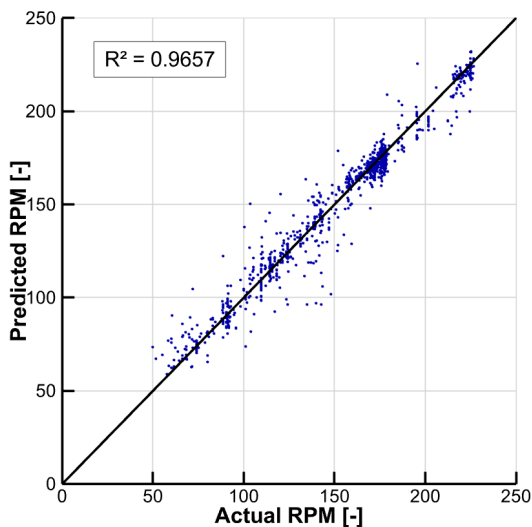


Fig. 18 Correlation analysis between actual RPM and predicted RPM by implementing supervised learning considering all variables (Case #3)




Fig. 19 Correlation analysis between actual power and predicted power by implementing supervised learning considering all variables (Case #3)

속도-축 동력의 예측 결과가 오손 효과 작용 기간을 고려하지 않았던 모델에 비하여 결정계수가 미미하게 향상되었다. 비록 그 효과가 뚜렷하지는 않지만, 오손 효과 작용 기간이라는 변수를 추가함으로써 속도-분당회전수, 속도-축 동력의 관계성에 관한 예측 정확도가 높아졌음을 알 수 있다.

Case #3 학습 모델을 이용한 예측 시, 오손 효과 작용 기간과 평균 흘수를 제외한 다른 변수는 학습에 이용된 실선 운항데이터 값을 동일하게 적용하였다. 먼저, 오손 효과 작용 기간을 실선 운항데이터 값을 적용한 예측과 0으로 처리한 예측을 각각 수행한 것은, 전체 표면 상태에 오손 효과가 고려된 경우와 오손 효과가 고려되지 않은 경우를 나누어 그 차이를 보기 위함이었다. 또한, 평균 흘수는 설계 흘수인 3.3m로 고정되어 있다고 가정, 각각의 예측에 3.3m를 적용하였다. 이것은 대상 선박이 국내 기자재 실증, 해상 관광 목적으로 운항하는 특성에 따라 운항 중 흘수가 일관적이지 않았기 때문이다. 평균 흘수의 변화가 축 동력의 변화에 미치는 영향이 매우 크기 때문에, 오손 효과로 인한 축 동력의 증가만을 정량적으로 분석하기 위해서 흘수를 고정할 필요가 있었다. 마지막으로, 설계 속도(14knots) 기준 축 동력의 $\pm 3\%$ 에 해당하는 데이터만을 학습 모델을 이용한 예측에 이용하였다.

Fig. 20은 오손 효과 작용 유무에 따라 상대 동력 증가율을 오손 효과 작용 기간에 따라 표시한 것이다. 오손 효과의 작용 유무에 따른 동력 차이를 설계 속도에서의 축 동력인 1,150kW로 나누는 것이다. 오손 효과 작용 기간이 증가함에 따라 오손 효과로 인한 상대 동력 증가율이 대체로 증가하는 경향성을 확인할 수 있었다. 진수 시점에 오손 효과가 없다고 가정함으로써, 오손 효과로 인한 상대 동력 증가율을 1차 식으로 회귀 분석 하였다. 이때, 기울기는 약 0.0468%/day였다. 울산태화호가 진수된 후, 1차 선저 청소를 하기까지 약 567일이 경과했고, 축 동력 증가는 약 305kW로 추정되었다. Table 3은 오손 효과로 인한 동력 증가의 기울기를 이용하여, 진수 후 0.5, 1.0, 1.5년이 지난 시점의

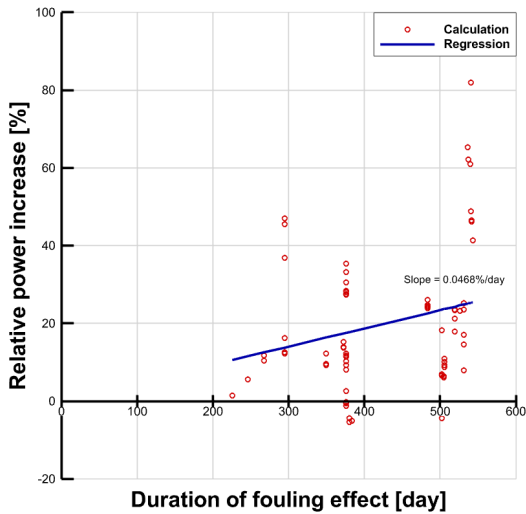


Fig. 20 Relative power increase between fouled and clean hull conditions at design speed

Table 3 Ratio between increased power and shaft power at design speed according to duration of fouling effect

Duration of fouling effect [year]	Increased power [kW]	Ratio between increased power and shaft power at design speed (Present approach) [%]	Ratio between increased power and shaft power at design speed (ISO 19030) [%]
0.5	98.3	8.55	11.06
1.0	196.6	17.09	22.11
1.5	294.9	25.64	33.17

축 동력 증가량과 상대 동력 증가율을 정리한 것이다. 진수 이후 1.5년이 경과한 시점에 축 동력의 증가율은 25.64%로써, 통상적인 시미진 15~30%과 비교할 때 매우 큰 동력 증가가 발생할 수 있음을 알 수 있다. ISO 19030에 제시된 오손 효과의 정량화 방법을 적용하여, 울산태화호가 진수된 시점부터 1차 선저 청소를 하기까지 오손 효과를 추정하였다. 본 논문에서 제시한 방법으로 추정된 오손 효과와 비교할 때, 오손 효과가 약 29.07% 크게 추정되고 있음을 확인할 수 있었다 (ISO, 2016).

물론, 보유한 실선 운항데이터는 진수 후 218일째부터 기록되어 있어, 진수 후 218일까지의 계측 데이터가 없어서 지도학습을 이용한 예측 모델 검증에 한계가 존재한다. 대상 선박에서 지속적으로 실선 운항데이터가 축적되고 있어, 충분한 시간이 지난 후 주기적인 선저 청소 이후의 오손 효과에 관한 재검토가 가능할 것으로 생각된다.

5. 결론

본 연구에서는 지도학습을 기반으로 2,700톤급 전기추진 스마트 선박의 실선 운항데이터를 분석함으로써, 대상 선박의 분당회

전수 및 축 동력 추정 방법론을 구축하는 것을 목표로 하였다. 또한, 오손 효과가 선박의 실선 운항 성능에 미치는 영향을 정량적으로 검토하고자 했다. 다음과 같이 세 가지 결론을 얻을 수 있었다.

첫째, 지도학습을 적용하여 실선 운항데이터 분석 및 예측 모델을 설계하였으며, 설계 변수에 따라 예측 모델의 정확성을 정량적으로 비교, 분석하였다. 특히, 최소자승법을 이용한 속도-분당회전수, 속도-축 동력 예측 결과에 비해서, 복수 설계 변수를 고려한 지도학습 모델을 적용한 예측 결과에서 뚜렷한 항상 효과가 관찰되었다.

둘째, 오손 효과 작용 기간이 추가된 복수 입력변수를 기준으로 지도학습을 적용함으로써, 속도-분당회전수, 속도-축 동력의 예측 결과를 더 향상할 수 있었다. 비록 그 효과가 미미하기는 했지만, 실선 운항데이터 내에서 오손 효과에 따른 분당회전수, 축 동력 증가 경향성이 예측에 반영되었다고 판단된다.

셋째, 학습 모델에서 선택된 설계 변수 중 오손 효과 작용 기간의 입력 또는 0으로 처리 여부에 따라, 오손 효과가 축 동력 증가에 미치는 영향을 정량적으로 분석할 수 있었다. 진수부터 선저 청소를 하기까지 약 567일 동안, 오손 효과로 인해 축 동력이 26.57% 증가한 것으로 평가되었다.

본 연구는 지도학습을 적용한 데이터 기반 실선 운항 성능 추정 연구의 초기 성과로 생각된다. 현재, 대상 선박의 수학모형, 실선 운항데이터를 조합한 모델 기반 실선 운항 성능 추정 연구가 병행되고 있어, 모델 기반 실선 운항 성능 추정 연구와 데이터 기반 실선 운항 성능 추정 연구의 정량적 비교 및 상호 보완이 가능할 것으로 기대한다.

후 기

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2024-00395678, 우수신진 연구). 또한, 이 성과는 정부(해양수산부)의 재원으로 한국수산업학기술진흥원의 지원을 받아 수행된 연구임(RS-2025-02219107, 녹색해운항로 확대 및 한국형 모델 개발).

Nomenclature

Abbreviation	Full meaning
CFD	Computational Fluid Dynamics
COG	Course Over Ground
ECMWF	European Centre for Medium-Range Weather Forecasts
ERA5	ECMWF Reanalysis v5
IMO	International Maritime Organization
KST	Korea Standard Time
RPM	Revolutions Per Minute
SOG	Speed Over Ground
UIPA	Ulsan ICT Promotion Agency
UTC	Universal Time Coordinated

References

- Aldous, L., Smith, T., Bucknall, R., and Thomson, P., 2015. Uncertainty analysis in ship performance monitoring. *Ocean Engineering*, 110, pp.29–38.
- Bassam, A.M., Dedes, E.K., Yang, Z., and Ni, M., 2022. Ship speed prediction based on machine learning for efficient shipping operation. *Ocean Engineering*, 245, 110449.
- Coraddu, A., Dubbioso, G., Mauro, S., and Viviani, M., 2013. Analysis of twin screw ships' asymmetric propeller behaviour by means of free running model tests. *Ocean Engineering* 68, pp.47–64.
- DeKeyser, S., Morobé, C., and Mittendorf, M., 2022. Towards improved prediction of ship performance: A comparative analysis on in-service ship monitoring data for modeling the speed-power relation. arXiv preprint arXiv:2212.13061.
- Demirel, Y.K., Song, S., Turan, O., Incecik, A., and Atlar, M., 2019. Practical added resistance diagrams to predict fouling impact on ship performance. *Ocean Engineering*, 183, 106129.
- Gupta, P., Rasheed, A., and Steen, S., 2022. Ship performance monitoring using machine-learning. *Ocean Engineering*, 254, 111094.
- Hair, J.F., Black, W.C., and Babin, B.J., Anderson, R.E., 2010. *Multivariate Data Analysis* (7th ed.). Prentice Hall.
- Hoof, J.P., 1994. The cross-flow drag on a manoeuvring ship. *Ocean Engineering*, 21(3), 329–342.
- Huang, Y., Mao, W., and Ringsberg, J.W., 2022. Ship performance prediction based on full-scale monitoring data using machine learning methods. *Ocean Engineering*, 251, 111145.
- ISO, 2016. Ships and marine technology – Measurement of changes in hull and propeller performance – Part 2: Default method. ISO 19030-2:2016(E). International Organization for Standardization, Geneva, Switzerland.
- Kang, M., You, Y., Kim, S., and Jung, S., 2025. A feasibility study on effects of fouling on speed and power for 2,700ton-class electric-propulsion smart ship by analyzing full-scale measurement data. *Journal of the Society of Naval Architects of Korea*, 62(4), 246–253.
- Kim, H., Kim, B., Kang, Y., and Ha, Y., 2021. Estimation of reference wind speeds in offshore of the Korean Peninsula using reanalysis data sets. *New & Renewable Energy*, 17(4), 1–8.
- KRISO (Korea Research Institute of Ships and Ocean Engineering), 2021. *Hull form study for HMD smartship*. Report BSPIS9790–12120–7.
- Lang, X., Wu, D., and Mao, W., 2022. Comparison of supervised machine learning methods to predict ship propulsion power at sea. *Ocean Engineering*, 245, 110387.
- Song, S., Demirel, Y.K., and Atlar, M., 2019. An investigation into the effect of biofouling on the ship hydrodynamic characteristics using CFD. *Ocean Engineering*, 185, 106164.
- Taylor, P.K., Kent, E.C., Kaplan, A., and Reynolds, R.W., 1994. The accuracy of marine surface winds from ships and buoys. *Journal of Atmospheric and Oceanic Technology* 11(6), pp.1204–1223.
- Terziev, M., Tezdogan, T., Demirel, Y.K., Oguz, E., Incecik, A., 2021. Scale effects and full-scale ship hydrodynamics: A review. *Ocean Engineering*, 231, 108857.
- Torii, R., and Kifune, H., 2023. Influence of propeller fouling on propulsion performance of an actual ship: A long-term analysis focusing on the power for keeping propeller's rotation of a controllable pitch propeller. *Journal of Marine Science and Technology*, 28, pp.1595–1607.
- Uzun, D., Demirel, Y.K., Turan, O., and Day, A.H., 2019. Time-dependent biofouling growth model for predicting the effects of biofouling on ship resistance and powering. *Ocean Engineering*, 191, 106462.
- Xie, G., Ren, H., Mao, W., Ringsberg, J.W., 2023. Full-scale ship performance prediction accounting for hull fouling and weather conditions using machine learning. *Applied Ocean Research*, 133, 103606.
- Yasukawa, H., and Yoshimura, Y., 2015. Introduction of MMG standard method for ship maneuvering predictions. *Journal of Marine Science and Technology*, 20(1), 37–52.
- You, Y., Choi, J.W., and Lee, D.Y., 2020. Development of a framework to estimate the sea margin of an LNGC considering the hydrodynamic characteristics and voyage. *International Journal of Naval Architecture and Ocean Engineering*, 12, pp.184–198.
- You, Y., Kim, J., and Seo, M., 2017. A feasibility study on the RPM and engine power estimation based on the combination of AIS and ECMWF database to replace the full-scale measurement. *Journal of the Society of Naval Architects of Korea*, 54(6), pp.501–514.
- You, Y., Kim, J., and Seo, M., 2018. Prediction of an actual RPM and engine power of an LNGC based on full-scale measurement data. *Ocean Engineering*, 147, 496–516.

