

선박 연료소모량 예측을 위한 데이터 설계 요인 영향 분석: 다중 요인 실험적 접근

차봉민^{1†}, 임흥준^{2†}, 이상봉³, 강성필⁴, 김동현^{5*}

¹부경대학교 데이터공학과 학생, ²부경대학교 산업및데이터공학과 학생, ³(주)랩오투원 대표,

⁴(주)랩오투원 이사, ⁵부경대학교 미래융합학부 기계조선공조공학전공 교수

Analysis of Data Design Factors Affecting Ship Fuel Consumption Prediction: A Multi-Factor Experimental Approach

Bong-Min Cha^{1†}, Heung-Jun Im^{2†}, Sang-Bong Lee³, Seong-Phil Kang⁴, Dong-Hyun Kim^{5*}

¹Student, Division of Data Engineering, Pukyong National University

²Student, Division of Industrial and Data Engineering, Pukyong National University

³CEO, LAB021 Co., Ltd.

⁴Director, LAB021 Co., Ltd.

⁵Professor, Division of mechanical, shipbuilding & air conditioning Engineering, Pukyong National University

요약 전 세계적으로 지속 가능한 미래에 대한 책임이 강화되면서 2050년 온실가스 순배출 제로 달성을 위한 노력이 가속화되고 있다. 이에 따라 전 세계 무역의 90% 이상을 담당하고 전체 인위적 탄소 배출량의 약 3%를 차지하는 해운 산업의 탈탄소화 필요성이 더욱 커지고 있다. 그러나 기존 연구는 운항 종료 후 확보되는 변수에 의존하거나 시간적 연속성과 데이터 완전성을 가정함으로써 실제 운항 환경에 적용하는 데 한계가 있었다. 본 연구는 항해 계획 단계에서 확보 가능한 변수만을 활용해 연료소모량을 예측하는 자동화 실험 프레임워크를 제안한다. 정상 운항 필터링, 입력 변수 표현 방식, 시간 해상도, 데이터 분할 방법, 목표 변수 선택, 모델 유형 등 핵심 실험 요소를 체계적으로 구성했다. Hydra를 활용해 요소 조합별 실험을 자동화하고, ANOVA 검정을 적용하여 각 요소의 예측 성능에 대한 기여도를 정량화했다. 연구 결과, 다양한 운항 조건 설정이 예측 정확도에 결정적인 영향을 미치는 것으로 나타났으며, 이러한 분석을 바탕으로 향후 에너지 효율적 항해 계획을 위한 데이터 설계 전략을 제시한다.

주제어 : 해운 탈탄소화, 연료소모량 예측, 선박 에너지 효율, 데이터 설계 전략, 요인 분석

Abstract With the strengthening global commitment to a sustainable future, efforts to achieve net-zero greenhouse gas emissions by 2050 are accelerating. Accordingly, the need for decarbonization in the maritime sector, which carries over 90% of global trade and produces about 3% of anthropogenic emissions, continues to grow. Yet many existing studies rely on post-voyage variables or assume temporal continuity and data completeness, limiting their applicability to real operations. This study proposes an automated experimental framework that predicts fuel oil consumption using only variables available at the voyage planning stage. Key experimental factors—normal-operation filtering, input representation, temporal resolution, data-splitting methods, target variable selection, and model type—are systematically defined. The Hydra framework automates experiments across factor combinations, and ANOVA quantifies each factor's contribution to prediction performance. Results show that operational condition settings strongly influence accuracy, and the study provides a data design strategy to support future energy-efficient voyage planning.

Key Words : Maritime Decarbonization, Fuel Consumption Prediction, Ship Energy Efficiency, Data Design Strategy, Factor Analysis

이 성과는 정부(과학기술정보통신부)의 재원으로 정보통신산업진흥원의 지원을 받아 수행된 연구임(S2201-24-1003, AI 기반 선박 온실가스 관리와 저감에 가능한 분석 엔진 및 API 서비스 개발).

*교신저자 : 김동현(dhkim8@pknu.ac.kr)

†공동 제 1저자

접수일 2025년 12월 02일

수정일 2025년 12월 18일

심사완료일 2025년 12월 22일

www.kci.go.kr

1. 서론

최근 기후변화 대응은 선택이 아닌 생존과 직결된 국제 사회의 필수 과제로 인식되며, 2050년까지 온실가스 배출을 '순 제로(Net-zero)' 수준으로 감축하려는 국제적 합의가 확산되고 있다. 이러한 흐름 속에서 산업 전반의 구조적 전환이 요구되고 있으며, 특히 해운산업은 전세계 무역량의 약 90%를 담당하고 전 지구 탄소 배출의 약 3%를 차지하는 주요 산업으로서 탈탄소화의 핵심 대상이 되고 있다[1, 2]. 국제해사기구(International Maritime Organization, IMO)의 규제 강화와 함께 선박 운항 효율을 개선하고 연료 소비를 절감하기 위한 기술적·운항적 접근이 활발히 시도되고 있다[3]. 그중에서도 운항 계획 수립 단계에서 연료소모량을 정확히 예측하는 것은 탄소 배출 저감 및 에너지 효율화의 출발점이자 전략적 의사결정의 핵심 요인으로 주목받고 있다[4].

그러나 기존의 예측 연구들은 주로 항해 완료 후 확보된 데이터를 기반으로 하거나, 시간 연속성과 데이터 완전성을 전제로 하는 등 실제 운항 환경과 괴리된 가정을 포함하는 경우가 많았다[5]. 이러한 접근은 학습 데이터의 과적합과 실제 예측 성능 저하로 이어지며, 운항 계획 단계에서 실시간으로 활용하기 어렵다는 한계를 지닌다[6]. 또한 사후 데이터에 의존한 설명적 모델링은 원인-결과와의 인과 관계를 단절시켜, 실질적인 예측보다는 사후 해석에 머무는 문제가 있었다[7]. 최근에는 LSTM, Transformer 등 고도화된 딥러닝 모델이 활용되고 있으나, 선박 운항 데이터의 불연속성·결측·센서 오차 등 현실적 제약을 충분히 반영하지 못해 산업 현장에서의 적용성이 낮은 실정이다[8-10].

이러한 한계를 극복하기 위해 본 연구는 운항 계획 단계에서 확보 가능한 변수만을 활용하여 연료소모량을 안정적으로 예측할 수 있는 데이터 설계 전략을 확립하는 것을 목표로 한다. 이를 위해 MLOps 기반의 Hydra 자동화 실험 프레임워크를 구축하고, 데이터 전처리 방식, 입력 변수 구성, 시간 해상도, 데이터 분할, 목표 변수, 모델 구조 등 주요 설계 요인을 모두 체계적으로 탐색하면서 연료소모량 예측 성능을 측정하였다[11, 12]. 각 요인별 실험 결과를 기반으로 분산분석(ANOVA)을 수행하여 예측 성능에 대한 요인별 기여도를 정량적으로 검증하였으며, 이를 통해 운항 데이터의 구조적 특성과 모델 일반화 성능 간의 관계를 규명하고자 하였다[13].

연구에는 2년 6개월 동안 운항한 7척(벌크선 6척, 유조선 1척)의 실선 데이터가 활용되었다. 약 56만 건의

10분 간격 운항 로그와 항차 보고서를 통합하여 운항·기 관·환경 변수를 포함하는 분석용 데이터셋을 구축하였으며, 운항 계획 단계에서 실제 활용 가능한 정보를 반영하기 위해 NOAA의 6시간 예보 데이터를 외력 변수로 사용하였다. 연구 결과, 시간 해상도와 데이터 분할 방식이 예측 성능에 가장 큰 영향을 미치는 핵심 요인으로 확인되었으며, 복잡한 비선형 모델보다 선형 회귀 기반의 단순 모델이 더 높은 일반화 성능을 보였다. 이는 실제 운항 데이터의 불완전성과 노이즈 특성으로 인해, 모델 구조의 복잡성보다 데이터 설계와 처리 전략의 적절성이 예측 정확도에 더 큰 영향을 미친다는 점을 실증적으로 보여준다. 이러한 결과는 향후 에너지 효율적 운항 계획과 탄소 배출 저감 전략 수립을 위한 데이터 기반 예측 체계 구축의 방향성을 제시한다.

2. 관련 연구

2.1 물리 기반 모델과 데이터 기반 모델

선박 연료 소모량 예측 방법은 크게 물리 기반 예측 방법과 데이터 기반 예측 방법으로 구분된다.

선박의 속도-동력 성능을 해상 시운전 데이터로부터 평가하는 국제 표준인 ISO 15016 (2015)[14]는 선박 저항을 평수 중 저항, 풍압저항, 파랑 부가 저항으로 구분하여 계산하는 방법을 제시한다. 그러나 F. Tillig et al. (2018)[15]의 연구에서는 물리 기반 모델이 파라미터 설정에 따라 결과가 민감하게 변한다는 점과, 새로운 조건에서는 예측 정확도가 급격히 떨어질 수 있다는 점을 언급하였다.

데이터 기반 모델은 선박의 연료 소모량 예측에서 물리 모델의 대안으로 활용되고 있다. 센서 데이터, AIS 데이터 등을 기반으로 연료 소모량의 패턴을 학습하며, 물리 파라미터를 정의하지 않은 채 높은 예측 정확도를 확보한다[16]. 그러나 머신러닝 모델에도 명확하게 한계가 존재한다. 학습 데이터 분포 외에 있는 운항 조건이나 이상환경에 대해서는 일반화 성능이 크게 저하된다는 단점이 있다.

2.2 딥러닝 모델의 적용과 한계

딥러닝 모델은 선박 연료 소모량 예측 연구에서 복잡한 비선형 관계와 시공간적 패턴을 효과적으로 포착하는 강점을 지닌다. 머신러닝 모델이 수작업으로 설계된 특

징을 기반으로 학습하는 것과 달리, 딥러닝 모델은 다층 신경망 구조를 통해 원시 데이터로부터 계층적으로 특징을 자동 추출하여 학습한다[18, 19].

선박 연료 소모량 예측을 위한 딥러닝 모델은 다양한 방향으로 발전하고 있다. 먼저, 표 형식 데이터에 특화된 학습 모델이 개발되어 선박 운항 데이터의 구조적 특성을 효과적으로 학습한다. 또한, 시계열 모델에 Attention 기법을 결합하여 시간에 따른 데이터의 장기 의존성과 중요한 시점을 선택적으로 학습하려는 시도가 이루어지고 있다. 최근에는 PINN(Physics-Informed Neural Networks) 방법이 주목받고 있는데, 이는 선박 저항 이론이나 유체역학과 같은 물리 법칙을 딥러닝 모델의 손실 함수나 구조에 직접 삽입하여 데이터와 물리 지식을 동시에 활용하는 하이브리드 접근법이다[20]-[22].

그러나 딥러닝 모델도 여러 한계점을 지닌다. 첫째, 대규모 데이터와 높은 계산 자원이 필요하다. 딥러닝 모델은 많은 파라미터를 학습하기 위해 충분한 양의 학습 데이터와 고성능 하드웨어를 요구하며, 이는 데이터나 자원이 제한적인 환경에서 적용을 어렵게 만든다. 둘째, 블랙박스 모델 특성상 해석 가능성이 낮다. 다층 신경망 구조를 통해 복잡한 비선형 관계를 학습하지만 내부의 사결정 과정을 명확히 설명하기 어려워 실무 적용의 장애가 된다. 마지막으로 과적합 위험이 크다는 단점이 있다. 학습 데이터에 지나치게 최적화되어 새로운 데이터에 대한 일반화 성능이 저하될 가능성이 높으며, 이를 방지하기 위한 정규화 기법이나 교차 검증 등의 추가적인 처리가 요구된다[23]-[25].

2.3 입력 변수 활용 방식

선박 연료 소모량 예측 연구는 사용하는 변수의 특성에 따라 두 가지 접근으로 구분된다. 동적 변수 기반 접근은 엔진 RPM, 축 동력, 추진기 회전수 등 항해 중 실시간으로 측정되는 변수를 활용하며, A. Laurie and E. Anderlini (2021)[26]의 연구에서 1-5%의 높은 예측 정확도를 달성하였다. 그러나 이러한 변수는 실제 운항 중에만 측정 가능하여 출항 전 연료 계획 단계에서는 활용할 수 없다는 한계가 있다[27]. 반면 출항 전 변수 기반 접근은 선박 속도, 적재량, 흘수, 풍속, 파고, 해류 등 항해 시작 시점에 확보 가능한 정보만을 사용한다. J. B. Lee et al. (2021)[28]은 해양환경 변수를 활용하여 선박 출력을 예측하였으나, 출항 전 변수만으로 연료 소모량을 직접 예측한 연구는 여전히 부족한 실정이다.

3. 데이터셋

본 연구에서는 2년 6개월 동안 운항한 총 7척 선박의 센서 데이터와 항차 보고서를 활용하여 예측 모델의 학습과 검증을 수행하였다. 대상 선박은 벌크선 6척과 유조선 1척으로 구성되며, 아시아, 유럽, 남아프리카, 오세아니아 등 다양한 항로를 운항하였다. 선박별 주요 제원은 Table 1에 제시하였다.

선박 센서 데이터는 10분 간격으로 수집되었으며, 총 약 56만 개의 시계열 데이터로 구성된다. 수집된 변수는 크게 운항 정보(위도, 경도, 속도, 선체 흘수, 방위각 등)와 기관 정보(메인 엔진 출력, 연료소모량 등)로 구분된다. 그리고 각 선박의 항차 보고서를 병합하여 운항 구간별 메타 정보를 확보하였다. 항차 보고서는 항차 번호, 출도착 항만 등의 정보를 포함하며, 이는 실험 구간 분류와 예측 성능 비교의 기준으로 활용되었다. 또한, 외력 정보는 운항 계획 단계에서 접근 가능한 예보 데이터를 반영하기 위해 NOAA에서 제공하는 6시간 후 예측 데이터를 사용하였다. 해당 데이터에는 바람, 조류, 파도, 수온, 해수 밀도 등의 변수가 포함된다.

<Table 1> Specification of target vessels

SHIP Info	SHIP A	SHIP B	SHIP C	SHIP D	SHIP E	SHIP F	SHIP G
Type	Dry bulk /Ultra Cape	Dry bulk /Ultra Cape	Dry bulk /Ultra Cape	Dry bulk /Ultra Cape	Dry bulk /Ultra Cape	Oil Tanker /Aframax(LR 2)	Dry bulk /Ultra Cape
Year Build	2018	2021	2019	2021	2021	2018	2011
Dead Weight	324,000	324,000	324,000	324,000	324,000	110,000	180,000

4. 실험 설계

본 연구의 목표는 실제 운항 계획 단계에서 활용 가능한 정보를 기반으로 강건하고 실무 적용이 가능한 연료 소모량 예측 프로세스를 구축하는 것이다. 이를 위해 입력 데이터의 설계 구성과 처리 방식이 예측 성능에 미치는 영향을 체계적으로 검증하고, 각 요인별 조합 효과를 정량적으로 분석하였다.

실제 해운 운항 데이터는 불연속성과 이상치, 결측, 제한된 데이터량 등 다양한 제약을 포함한다. 따라서 본 연구에서는 사후 취득 변수나 복잡한 후처리 절차를 배

제하고, 현실적 운항 조건을 반영한 변수 및 전처리 전략을 중심으로 실험을 설계하였다. 자세한 실험 구성은 (1) 비정상 운항 구간 필터링, (2) 입력 변수 구성, (3) 시간 해상도, (4) 데이터 분할 방식, (5) 목표 변수, (6) 모델 구조로 총 6가지 설계 요인으로 정의된다. 모든 실험은 Meta의 Hydra 프레임워크를 활용하여 자동화된 파이프라인으로 수행되며, 이후 ANOVA(Analysis of Variance) 분석을 통해 각 설계 요인의 상대적 영향력을 검증하였다.

해양 운항 데이터는 노이즈와 이상값이 혼재되어 있으므로, 신뢰할 수 있는 입력 구간 확보를 위해 기본 전처리를 수행하였다. 기본 전처리는 크게 3가지로 원시 CSV 데이터 로드, 결측 및 중복 제거, 물리적으로 불가능한 값 제거로 구성된다. 특히, NaN, -9999 같은 결측치나 $RPM \leq 0$, $FOC < 0$ 또는 $WAVE PERIOD = 0$ 과 같은 값들을 제거하였다. 이러한 전처리 과정을 통해 안정적인 학습용 데이터셋을 확보하였다.

모든 실험은 동일한 하드웨어 및 소프트웨어 환경에서 수행하였다. 학습에는 NVIDIA GeForce RTX 2080 Ti GPU (VRAM 11GB)를 사용하였으며, CPU는 Intel Xeon Gold 6230R, 시스템 메모리는 약 515GB이다. CUDA 12.4 및 NVIDIA Driver 550.76 환경에서 실험을 진행하였고, 딥러닝 프레임워크로는 PyTorch 2.4를 사용하였다.

4.1 설계요인 (1): 비정상 운항 구간 필터링

기본 전처리 이후, 비정상 운항 구간을 필터링하여 정상 운항 데이터만을 선별한다. 비정상 운항 필터링 조건의 강도가 예측 성능에 미치는 영향을 분석하기 위해 Table 2와 같이, 두 가지 기준을 정의하였다.

〈Table 2〉 Criteria for Filtering Normal Operation Sections

Category	Condition 1	Condition 2
Basic Criteria	$RPM > 1$ & $SPEED > 1$	$POWER > 500$ within the last 1 hour
Conservative Criteria	$RPM > 2$ & $SPEED > 0.5$	

Basic Criteria는 데이터 확보량을 극대화하여 모델의 일반화 성능을 강화하는 반면, Conservative Criteria는 고품질 데이터만 선별하여 예측 정밀도를 향상시킨다. 두 기준의 트레이드오프 관계를 비교함으로써, 최적의 필터링 강도를 탐색하고자 하였다.

4.2 설계요인 (2): 입력 변수 구성

입력 변수는 운항 변수와 외력 변수로 구분하여 설계하였다. 운항 변수는 모든 실험에서 고정되어 사용되며 대지속도, 방위각, 평균 홀수, 화물적재량(항차 기준 적재량)으로 구성된다. 외력 변수는 조류, 파랑, 바람, 수온, 해수 밀도 등으로 구성되며, Table 3과 같이 세 가지 축 기준으로 총 8가지 조합을 생성하였다.

〈Table 3〉 Configuration Options for Environmental Variable Representation

Criteria	Description
Magnitude Basis	<ul style="list-style-type: none"> ABS: Uses the absolute magnitude and direction of external forces. REL: Converts to relative values based on the vessel's reference frame.
Direction Basis	<ul style="list-style-type: none"> ABS: Uses the absolute magnitude and direction as measured. VECTOR: Converts directional variables into UV/VW vector components.
Forecast Basis	<ul style="list-style-type: none"> NOWCAST: Real-time observed environmental data. FORECAST: Predicted data from NOAA with a 6-hour lead time.

4.3 설계요인 (3): 시간 해상도

로그 데이터는 10분 간격으로 수집되며 단기 변동성이 존재한다. 이를 완화하기 위해 10 min, 1h, 3h, 6h, 12h, 24h로 6단계 시간 해상도 옵션을 설정하였다. 각 구간은 단순 평균으로 다운샘플링하여 각 효과를 분석하였다. 시간 해상도가 커질수록 단기 노이즈가 감소하지만 정보 손실이 발생하므로, 이 관계를 실험적으로 검증하였다.

4.4 설계요인 (4): 데이터 분할 방식

시간적 연속성을 고려하기 위해 두 가지 데이터 분할 전략을 적용하였다. 첫 번째 방식인 Group chronological은 전체 데이터를 시간 순으로 정렬한 뒤 처음 80%를 학습용으로, 이후 20%를 테스트용으로 분할한다. 두 번째 방식인 Group random은 전체 데이터를 무작위로 섞은 후 80%를 학습용으로, 20%를 테스트용으로 분할한다. 이를 통해 시간 순서의 유지 여부가 예측 성능에 미치는 영향을 평가하였다.

4.5 설계요인 (5): 목표 변수

선박 운항 데이터 기반 예측 연구에서의 목표 변수는 일반적으로 연료소모량을 단일 변수로 설정해왔다. 본

연구에서는 기존 FOC 예측에 더하여 엔진 회전수를 의미하는 RPM을 추가 목표 변수로 설정하여 다양한 경우의 수를 통해 각 목표 변수가 예측 성능에 미치는 영향을 비교 분석한다.

4.6 설계요인 (6): 사용 모델

본 연구는 입력 구성의 변화가 예측 성능에 미치는 영향을 균형적으로 분석하기 위해, XGBoost와 선형 회귀(Lasso를 포함한 Linear Regression) 두 가지 모델 구조를 채택하였다. XGBoost는 비선형 상호작용과 변수 간 복합 관계를 효과적으로 학습할 수 있어 입력 설계의 복잡도 변화에 따른 성능 변화를 파악하는데 적합하다 [29]. 반면, 선형 회귀 모델은 해석이 직관적이며 각 입력 변수가 예측에 미치는 영향을 명확히 파악할 수 있다[30].

이 두 모델은 상이한 학습 메커니즘을 가지므로, 본 연구에서는 동일한 데이터 조건과 실험 조합 하에서 두 모델의 예측 성능을 비교함으로써 입력 구조 및 데이터 처리 전략의 효과를 다각적으로 평가하였다.

4.7 실험 분석 구성 요약

본 연구는 해운 운항 데이터의 현실적 제약을 반영하여, 입력 구조와 데이터 처리 방식이 예측 성능에 미치는 영향을 체계적으로 분석하기 위한 실험 구성을 설계하였다. 앞서 설명한 ‘비정상 운항 구간 필터링, 입력 변수 구성, 시간 해상도, 데이터 분할 방식, 목표 변수, 사용 모델’을 조합하면 이론적으로 768가지 실험 구성이 가능하다. 그러나 모든 조합을 탐색하기보다는, 각 요인이 예측 성능에 미치는 영향을 분석하는 연구 목적에 부합하도록 대표 조합을 선정하였다. 대표 조합은 실제 연료 소모량 예측 도메인에서 널리 활용되고 실운항 환경에서 안정적으로 수집 가능한 변수를 기준으로 구성하였으며, 이때 각 실험 요인별로 고려한 선택지의 경우의 수를 Table 4에 제시하였다.

특히 외력 변수 구성에서는 절댓값과 방향 벡터 표현 간의 성능 차이를 중점적으로 검증하여, 외력 표현 방식이 예측 결과에 미치는 영향을 분석하였다. 선정된 조합은 Meta의 Hydra 프레임워크를 통해 자동화된 실험 파이프라인으로 수행되며, 결과는 ANOVA 분석을 통해 각 설계 요인의 기여도를 정량적으로 평가하였다. 이러한 현실 데이터 환경을 반영한 실험 설계를 통해 운항 계획 단계에서 활용 가능한 데이터 설계 및 처리 전략의 최적화 방안을 제시하고자 한다.

<Table 4> Experimental design factors and options

Factor	Abnormal Operation Filter	Environmental Input	Time Resolution	Data Split	Target Variable	Model Structure
Options	Basic Criteria	vector nowcast	10 min (none)	group chronological	ME1 RPM	Linear Regression
			1 h	group random	ME1 FOC	XGBoost
	Conservative Criteria	abs nowcast	3 h			
			6 h			
			12 h			
		24 h				

5. 실험 결과

본 절에서는 설정된 여섯 가지 설계 요인을 바탕으로 수행된 예측 실험의 결과를 제시한다. 각 요인이 모델의 일반화 성능에 미치는 영향을 정량적으로 평가하기 위해 분산분석(ANOVA)을 적용하였으며, 집단 간 평균 차이가 단순한 우연이 아닌 특정 요인의 변화에 의해 발생했는지를 검증하였다.

모든 성능 평가는 결정계수(R^2)를 주요 지표로 사용하였다. R^2 는 예측값이 실제값의 분산을 얼마나 설명하는지를 나타내며, 다양한 데이터 조건에서의 예측 안정성과 일반화 성능을 평가하는 데 적합하다. 본 연구에서는 7척의 선박 데이터를 독립 실험 단위로 설정하고, 각 실험 조합별 R^2 의 평균값을 종속 변수로 활용하였다.

5.1 요인별 모델 예측 성능 비교

본 절에서는 7척 선박의 개별 실험 결과를 평균하여, 각 설계 요인이 예측 성능에 미치는 전반적 경향을 비교·분석하였다. Table 5에 모델 유형, 데이터 분할 방식, 목표 변수, 외력 변수에 대해 주요 요인별 성능 비교를 요약한 결과를 제시하였다.

전체적으로 Linear Regression이 XGBoost보다 모든 조건에서 높은 평균 R^2 를 보였다. 모델별 비교 기준으로 Linear Regression은 0.6636, XGBoost는 0.3988을 기록하였으며, 두 모델 간 차이는 $p < 10^{-95}$ 수준에서 통계적으로 유의하였다. 이러한 결과는 복잡한 비선형 구조를 학습하는 XGBoost보다, 단순한 선형 모델이 본 데이터의 관계 구조를 보다 안정적으로 설명함을 의미한다.

데이터 분할 방식에 따라서는 시간 순서를 유지하는 group chronological 조건에서 R^2 가 더 높게 나타났다. 반면 무작위 분할인 group_random에서는 두 모델

모두 성능이 저하되었다. 이는 시간 흐름에 따른 데이터 분포 차이를 고려하지 않으면 학습-검증 간 불일치가 발생함을 시사한다.

목표 변수별로는 FOC 예측에서 모델 간 성능 격차가 약 0.29로 가장 크게 나타났으며, RPM 예측의 경우 두 모델 모두 상대적으로 높은 설명력을 보였다. 이는 FOC가 다변량적 영향 요인을 더 많이 포함하고 있어 모델링 난이도가 높기 때문으로 해석된다.

외력 변수 구성에서는 절댓값 기반 변수와 벡터 기반 변수 모두에서 Linear Regression이 XGBoost보다 우수했으며, 벡터 표현을 사용했을 때 약간의 성능 향상이 확인되었다. 이는 바람·파도·조류 등의 방향 정보를 벡터 형태로 반영하는 것이 예측 성능 향상에 유효함을 보여준다.

<Table 5> Summary of Factor-wise Model Performance Comparison

Factor	Condition	Linear (R ²)	XGBoost (R ²)	Difference	p-Value
Model	Overall mean	0.6636	0.3988	0.2648	9.22×10 ^{-96*}
Data Split	group chronological	0.7049	0.4854	0.2196	3.00×10 ^{-55*}
	group random	0.6223	0.3122	0.3101	1.24×10 ^{-48*}
Target Variable	ME1 FOC	0.6277	0.3418	0.2859	9.43×10 ^{-44*}
	ME1 RPM	0.6995	0.4558	0.2437	2.44×10 ^{-50*}
Environmental Input	abs nowcast	0.6602	0.388	0.2722	4.93×10 ^{-50*}
	vector nowcast	0.667	0.4097	0.2573	2.13×10 ^{-47*}

시간 해상도에 따른 모델 성능은 Table 6에 제시하였다. 10분 단위의 원시 데이터에서는 두 모델 모두 낮은 성능을 보였으며, 평균화 간격이 1h에서 24h로 길어질수록 예측 안정성이 점진적으로 개선되었다. Linear Regression의 R²는 0.5774에서 0.7493까지 향상되었고, XGBoost 또한 0.1890에서 0.5277로 증가하였다. 시간 해상도가 커질

<Table 6> Model Performance by Time Resolution

Resolution	Linear (R ²)	XGBoost (R ²)	Difference	p-Value
10 min (none)	0.5774	0.189	0.3884	1.03×10 ^{-18*}
1 h	0.6173	0.3532	0.2641	7.37×10 ^{-13*}
3 h	0.6499	0.3855	0.2644	5.34×10 ^{-13*}
6 h	0.6733	0.4361	0.2371	2.28×10 ^{-21*}
12 h	0.7144	0.5013	0.2131	2.26×10 ^{-22*}
24 h	0.7493	0.5277	0.2216	6.74×10 ^{-25*}

수록 단기 노이즈가 완화되어 입력 데이터의 신호 품질이 개선되는 효과가 나타난 것으로 판단된다.

선박별 모델 성능은 Table 7에 정리하였다. 모든 선박에서 Linear Regression이 XGBoost보다 높은 성능을 기록하였으며, 평균 차이는 약 0.25 수준이었다. 특히 SHIP D와 SHIP B에서 0.35 이상으로 성능 격차가 가장 컸고, SHIP A와 SHIP E에서는 0.12 이하로 비교적 작은 차이를 보였다. 이는 선박별 데이터 품질, 선박 제원, 운항 특성 등의 차이가 모델 학습 안정성에 영향을 미친 결과로 추측된다.

<Table 7> Model Performance by Vessel

Ship ID	Linear (R ²)	XGBoost (R ²)	Difference	p-Value
SHIP A	0.7127	0.653	0.0597	2.57×10 ^{-15*}
SHIP B	0.5669	0.2129	0.354	1.39×10 ^{-20*}
SHIP C	0.5099	0.1713	0.3386	1.49×10 ^{-14*}
SHIP D	0.6106	0.2359	0.3747	4.72×10 ^{-32*}
SHIP E	0.7897	0.6769	0.1128	1.39×10 ^{-21*}
SHIP F	0.6617	0.3833	0.2784	1.07×10 ^{-17*}
SHIP G	0.7937	0.4583	0.3354	6.11×10 ^{-16*}

5.2 Linear Regression 모델 내 요인별 영향력 분석

본 절에서는 앞선 절에서 더 좋은 일반화 성능을 보여준 Linear Regression 모델을 대상으로 주요 설계 요인들이 예측 성능에 미치는 영향을 분석하였다. Table 8에서 비정상 운항 구간 필터링, 데이터 분할 방식, 목표 변수, 외력 변수에 대해 주요 요인별 비교 결과를 제시하였다. Condition은 분석에 사용된 요인을 의미한다. Mean R²는 각 요인을 적용했을 때 7개 척도에서 산출된 R²의 평균값이다. Difference는 두 조건에서 산출된 Mean R² 간의 차이이다. p-value는 두 조건에서 산출된 Mean R² 차이에 대한 통계적 유의확률을 의미한다.

비정상 운항 구간 필터링의 경우 default 조건과 conservative 조건의 평균 R² 차이는 0.0005로, p = 0.450 수준에서 통계적으로 유의하지 않았다. 이는 정의된 임계 조건 내에서는 이상치 제거 기준이 모델 성능에 거의 영향을 주지 않음을 의미한다.

데이터 분할 방식에서는 group chronological 조건이 group random 조건보다 약 0.083 높은 R²를 보였다. 이는 시계열 데이터의 시간적 연속성을 보존하는 분할이 모델의 일반화 성능을 높인다는 점을 보여준다.

목표 변수 비교에서는 ME1 RPM 조건이 ME1 FOC

조건보다 약 0.072 높은 R²를 기록하였다. 이는 FOC보다 RPM이 모델링이 단순한 선형 관계로 설명될 가능성이 높음을 시사한다.

외력 변수 표현 방식 비교에서는 vector_nowcast가 abs_nowcast보다 0.0068 높았으며, 이 결과는 바람, 조류, 파랑 등의 방향 정보를 벡터 형태로 표현하는 것이 모델의 예측 안정성 향상에 기여함을 보여준다.

<Table 8> Summary of Factor-wise Effects within Linear Regression Model

Factor	Condition	Mean R ²	Difference	p-Value
Abnormal Operation Filter	default	0.6633	0.0005	0.450
	conservative	0.6639		
Data Split	group chronological	0.7049	-0.0827	1.72×10 ^{-11*}
	group random	0.6223		
Target Variable	ME1 RPM	0.6995	-0.0719	5.96×10 ^{-27*}
	ME1 FOC	0.6277		
Environmental Input	vector nowcast	0.6670	-0.0068	1.11×10 ^{-6*}
	abs nowcast	0.6602		

Table 9은 시간 해상도 변화에 따른 Linear Regression 모델의 성능 변화를 정리한 것이다.

10분 단위 원시 데이터에서 24시간 간격까지 확대할 수록 R² 값이 0.5774에서 0.7493으로 향상되었으며, 최소-최대 간 차이는 0.1719에 달하였다. 이는 장기 평균화가 단기 노이즈를 완화하고, 입력 데이터의 안정성을 높여 예측 정확도를 향상시킨 결과로 해석된다. 시간 해상도 변화에 따른 성능 차이에 대해 수행한 ANOVA 결과, p-value는 1.25×10⁻¹²로 통계적으로 유의한 차이가 확인되었다.

<Table 9> Effect of Time Resolution on Linear Regression Model

Time Interval	Mean R ²	Difference from Previous
10 min (none)	0.5774	-
1 h	0.6173	0.0399
3 h	0.6499	0.0326
6 h	0.6733	0.0234
12 h	0.7144	0.0411
24 h	0.7493	0.0349

이상의 결과를 종합하면, Linear Regression 모델 내에서 시간 해상도, 데이터 분할 방식, 목표 변수가 예측 성능에 가장 큰 영향을 미치는 요인으로 확인되었다. 반면 외력 변수의 표현 방식은 미세한 차이만을 보였으며, 비정상 운항 필터링 기준은 영향이 미미하였다.

6. 결론 및 향후 연구 방향

본 연구는 운항 계획 단계에서 확보 가능한 변수를 기반으로, 연료소모량 예측을 위한 체계적이고 재현 가능한 프로세스를 구축하였다. 이를 위해 예측 성능에 영향을 미치는 여섯 가지 설계 요인인 비정상 운항 구간 필터링, 외력 변수 구성, 시간 해상도, 목표 변수, 데이터 분할 방식, 모델 구조를 정의하고, 각 요인의 복수 옵션을 조합하여 Meta의 Hydra 프레임워크를 통해 자동화된 실험을 수행하였다. 분산분석(ANOVA)을 이용한 통계 검정 결과, 모델 구조보다는 데이터 설계와 전처리 전략이 예측 성능을 결정짓는 핵심 요인임을 정량적으로 확인하였다. 특히 시간 해상도를 24시간 단위로 재구성하고, 시간 순서를 보존한 데이터 분할 방식을 적용했을 때 가장 높은 예측 정확도가 나타났으며, 복잡한 비선형 모델인 XGBoost보다 단순한 Linear Regression이 일관된 일반화 성능을 보였다. 반면, 외력 변수 표현 방식과 비정상 구간 필터링 강도는 상대적으로 영향력이 제한적이었다. 이러한 분석을 바탕으로 도출된 최적 조합은 24시간 단위의 시간 해상도, 시간 순서를 보존한 데이터 분할 방식, RPM 기반 목표 변수, 벡터 기반 외력 표현, 선형 회귀 모델로 구성되었으며, 이 설정에서 가장 높은 예측 정확도와 일반화 성능이 나타났다. 이는 실제 해상 운항 데이터가 결측 노이즈를 다수 포함하는 특성상, 모델의 복잡도보다 입력 데이터의 안정성과 구조적 규제가 예측 신뢰도에 더 큰 영향을 미친다는 점을 실증적으로 보여준 결과이다.

본 연구의 의의는, 기존 연구들이 주로 모델 성능 향상에 초점을 맞춘 것과 달리, 데이터 설계 요인의 조합적 탐색과 통계적 검증을 통해 예측 시스템의 근본적 신뢰성과 일반화 가능성을 규명했다는 점에 있다. 또한 MLOps 기반의 자동화 실험 환경을 적용함으로써 재현성과 확장성을 확보하였고, 각 설계 요인의 상대적 영향력과 우선순위를 과학적으로 제시함으로써 향후 해운 데이터 기반 의사결정 시스템 구축의 객관적 기준을 마련하였다. 이러한 접근은 단순한 성능 비교를 넘어, 데이터

설계 중심의 모델 개발 패러다임을 제시했다는 점에서 학문적 의의를 가지며, 실제적으로는 향후 선박 운항 효율화, 최적 선속 결정, 탄소 배출 저감 전략 수립 등과 같은 응용 연구의 핵심 기초로 활용될 수 있다.

향후 연구에서는 본 연구에서 도출된 최적의 데이터 설계 및 모델링 전략을 기반으로, 실제 항차별 운항 조건을 입력으로 받아 연료 소비와 탄소 배출을 최소화하는 최적 선속 의사결정 알고리즘을 개발할 예정이다. 이를 통해 해운 산업의 탄소중립(Net-zero) 목표 달성에 기여하고, 운항 계획 단계에서의 에너지 효율적 전략 수립을 위한 실질적 지원체계를 제시하고자 한다.

REFERENCES

- [1] EMSA, Discover the EU Maritime Profile[Internet], <https://www.emsa.europa.eu/eumaritimeprofile.html>
- [2] Transport & Environment, Ships[Internet], <https://www.transportenvironment.org/topics/ships>
- [3] IMO, Initial IMO Strategy on Reduction of GHG Emissions from Ships, Resolution MEPC.304(72)[Internet], [[https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.304\(72\).pdf](https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.304(72).pdf)]([https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.304\(72\).pdf](https://wwwcdn.imo.org/localresources/en/KnowledgeCentre/IndexofIMOResolutions/MEPCDocuments/MEPC.304(72).pdf))
- [4] G.Gkerekos, I.Lazakis and G.Theotokatos, "Machine Learning Models for Predicting Ship's Main Engine Fuel Oil Consumption: A Comparative Study," *Ocean Engineering*, Vol.188, pp.106282, 2019.
- [5] K.Hajli, M.Rönnqvist, C.Dadouchi and J.Audy, "A Fuel Consumption Prediction Model for Ships Based on Historical Voyages and Meteorological Data," *Journal of Marine Engineering and Technology*, Vol.23, No.6, pp.439-450, 2024.
- [6] Y.Kim, P.Gupta and S.Steen, "A Comprehensive Review of Data Processing for Ship Performance Analysis," *Applied Ocean Research*, Vol.162, pp.104737, 2025.
- [7] G.Shmueli, "To Explain or to Predict?," *Statistical Science*, Vol.25, No.3, pp.289-310, 2010.
- [8] [X.Li(<http://x.li/>), Y.Zuo and J.Jiang, "DAPNet: A Dual-Attention Parallel Network for the Prediction of Ship Fuel Consumption Based on Multi-Source Data," *Journal of Marine Science and Engineering*, Vol.12, No.11, pp.1945, 2024.
- [9] A.Nguyen, R.Fablet, J.Gorcin, B.Mourre and G.Tandeo, TrAISformer—A Transformer Network with Sparse Augmented Data Representation and Cross Entropy Loss for AIS-based Vessel Trajectory Prediction[Internet], <https://arxiv.org/abs/2109.03958>
- [10] K.Alexiou, E.G.Pariotis and H.C.Leligou, "Sensor Data Quality in Ships: A Time Series Forecasting Approach to Compensate for Missing Data and Drift in Measurements of Speed through Water Sensors," *Designs*, Vol.7, No.2, pp.46, 2023.
- [11] D.Kreuzberger, N.Kühl and S.Hirschl, *Machine Learning Operations (MLOps): Overview, Definition, and Architecture*[Internet], <https://arxiv.org/abs/2205.02302>
- [12] O.Yadan, Hydra - A framework for elegantly configuring complex applications[Internet], <https://github.com/facebookresearch/hydra>
- [13] R.A.Fisher, *Statistical Methods for Research Workers*, 1st ed., Edinburgh: Oliver and Boyd, 1925.
- [14] ISO 15016:2015, "Ships and marine technology—Measurement of speed and power—Sea trials," International Organization for Standardization, Geneva, Switzerland, 2015.
- [15] F. Tillig, J. W. Ringsberg, W. Mao, B. Ramne, "Analysis of uncertainties in the prediction of ships' fuel consumption - from early design to operation conditions", *Ships & Offshore Structures*, vol. 13, no. sup-1, pp. 13-24, 2018. [Online] doi:10.1080/17445302.2018.1425519.
- [16] R. F. Melo, N. M. de Figueiredo, M. S. G. Tobias and P. Afonso, "A Machine Learning Predictive Model for Ship Fuel Consumption," *Appl. Sci.*, vol. 14, Art. no. 7534, 2024. doi:10.3390/app14177534.
- [17] J. Son and J.-H. Kim, "Pre-Departure Ship Fuel Consumption Prediction Under Out-of-Distribution Condition," SSRN, Jul. 2025.
- [18] Jeon M., Noh Y., Shin Y., Lim O-K., Lee I., Cho D., "Prediction of ship fuel consumption by using an artificial neural network", *Journal of Mechanical Science and Technology*, Vol 32, pp. 5785-5796, 2018. <https://doi.org/10.1007/s12206-018-1126-4>
- [19] Du Y., Y. Chen, X. Li, A. Schönborn, Z. Sun, "Data fusion and machine learning for ship fuel efficiency modelling: Part II - Voyage report data, AIS data and meteorological data," *Communications in Transportation Research*, vol. 2, p. 100074, 2022.
- [20] S. O. Arık, T. Pfister, "TabNet: Attentive Interpretable Tabular Learning," *arXiv preprint arXiv:1908.07442*, 2019.
- [21] H. J. Park, M. S. Lee, D. I. Park, and S. W. Han, "Time-aware and feature similarity self-attention in vessel fuel consumption prediction," *Appl. Sci.*, vol. 11, no. 23, p. 11514, 2021, doi: 10.3390/app11231151.
- [22] Uzun, M., Demirezen, M. U., and Inalhan, G., "Physics Guided Deep Learning for Data-Driven Aircraft Fuel Consumption Modeling," **Aerospace**, vol. 8, no. 2, Art. 44, 2021. doi:10.3390/aerospace8020044.
- [23] N. C. Thompson, K. Greenewald, K. Lee, and G. F.

Manso, "The computational limits of deep learning," arXiv preprint arXiv:2007.05558, 2020.

- [24] B. Seo, S. Choi, B. Kim, and Y. Jeon, "Explainable machine learning by SEE-Net: closing the gap between accuracy and interpretability," Nature Communications, vol. 15, no. 8979, 2024.
- [25] T. A. Oladipupo, C. O. Olaniyan, and O. P. Ogunbode, "Generalized performance of LSTM in time-series forecasting," Journal of Data Science and Intelligent Systems, vol. 2, pp. 24-43, 2024.
- [26] A. Laurie, E. Anderlini, "Machine learning for shaft power prediction and analysis of fouling-related performance deterioration," Ocean Engineering, vol. 234, 108886, Jun. 2021.
- [27] K. Wang, D. Zhang, Z. Shen, W. Zhu, H. Ye, and D. Li, "Novel ship fuel consumption modelling approaches for speed and trim optimisation: Using engine data as auxiliary," Ocean Engineering, vol. 286, p. 115520, Oct. 2023, doi: 10.1016/j.oceaneng.2023.115520.
- [28] J. B. Lee, M. Noh and K. Kim, "Prediction of ship power based on variation in deep feed-forward neural network," International Journal of Naval Architecture and Ocean Engineering, vol. 13, pp. 641-649, 2021.
- [29] T.Chen and C.Guestrin, "XGBoost: A Scalable Tree Boosting System," in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, 2016, pp.785-794.
- [30] R.Tibshirani, "Regression Shrinkage and Selection via the Lasso," Journal of the Royal Statistical Society, Series B (Statistical Methodology), Vol.58, No.1, pp.267-288, 1996.

차 봉 민(Bong-Min Cha) [준회원]



- 2024년 2월 : 부경대학교 국제경영학과(학사)
- 2024년 3월 ~ 현재 : 부경대학교 데이터공학과 석사과정 진행 중

<관심분야>
해운 데이터 분석, 인공지능, 빅데이터

임 흥 준(Heung-Jun Im) [준회원]



- 2025년 8월 : 부경대학교 시스템경영안전공학부(학사)
- 2025년 9월 ~ 현재 : 부경대학교 산업및데이터공학과 석사과정 진행 중

<관심분야>
해운 탈탄소화, 선박 최적운항, 인공지능

이 상 봉(Sang-Bong Lee) [정회원]



- 2004년 2월 : 한국해양대학교 기관시스템공학과(학사)
- 2005년 ~ 2010년 : 한진해운 1등 기관사(선박 관리)
- 2010년 ~ 2015년 : 뉴월드마리타임 연구소장(개발 총괄)
- 2015년 1월 ~ 현재 : 랩오투원 대표이사

<관심분야>
해운 데이터 분석, 인공지능, 해운 탈탄소 솔루션 개발

강 성 필(Seong-Phil Kang) [정회원]



- 2011년 2월 : 한국해양대학교 기관시스템공학과(학사)
- 2020년 2월 : 부산대학교 ICT 융합학과(석사)
- 2012년 4월 ~ 2016년 4월 : 한진해운 1등 기관사

- 2016년 6월 ~ 2016년 12월 : 한주상운 공무감독
- 2016년 12월 ~ 현재 : 랩오투원 제품개발부 이사

<관심분야>
해운 데이터 분석, 인공지능, 해운 탈탄소 솔루션 개발

김 동 현(Dong-Hyun Kim)

[정회원]



- 2010년 2월 : 부경대학교 조선행양시스템공학과(공학사)
- 2012년 8월 : 부경대학교 조선행양시스템공학과 (공학석사)
- 2019년 8월 : 부경대학교 조선행양시스템공학과 (공학박사)

- 2010년 10월 ~ 2023년 2월 : 한국조선행양기자재연구원 책임연구원
- 2023년 3월 ~ 현재 : 부경대학교 조교수

<관심분야>

이상치 탐지, 탄소중립, 선박 최적운항