

기계학습기반의 근사모형을 이용한 선박 횡동요 운동 예측

김영릉* · † 박준범 · 문성배**

*한국해양대학교 대학원, **,† 한국해양대학교 항해학부 교수

Prediction of Ship Roll Motion using Machine Learning-based Surrogate Model

Young-Rong Kim* · † Jun-Bum Park · Serng-Bae Moon**

*Graduate School of Korea Maritime and Ocean University, Busan 49112, Korea

**† Professor, Division of Navigation Science, Korea Maritime and Ocean University, Busan 49112, Korea

요 약 : 한국형 e-Navigation의 내항성 안전 모듈은 운항 중인 선박을 실시간으로 모니터링하고 내항성의 이상 상태를 사전에 경고함으로써 선박의 안정성을 확보하는 선내 원격 모니터링 서비스 중 하나이다. 일반적으로 선박설계를 위한 내항성능은 주어진 조건에서 전체 운동 시뮬레이션을 수행하여 평가하여 왔다. 하지만 운항 중 선박의 내항성능을 실시간으로 평가하기 위해 이러한 시뮬레이션을 실제 운항조건에 맞추어 수행하는 것은 계산시간의 한계로 인해 현실적이지 않다. 본 연구에서는 기계학습 기반의 근사모형을 활용하여 선박의 내항성능 평가 요소들 중 하나인 횡동요 운동특성을 합리적으로 보다 빠르게 예측하는 방법을 소개하고자 한다. 다양한 학습 기법과 데이터의 샘플링 조건을 적용하여, 얻어진 근사모형의 결과와 운동해석 결과의 오차가 거의 1% 내로 일치함을 보였다. 따라서 이러한 방법을 활용하면 선박의 실시간 내항성능을 평가하는데 효율적으로 사용할 수 있을 것으로 판단된다.

핵심용어 : 내항성능 평가, 횡동요 운동 예측, 기계학습, 근사모형, 한국형 e-Navigation

Abstract : Seakeeping safety module in Korean e-Navigation system is one of the ship remote monitoring services that is employed to ensure the safety of ships by monitoring the ship's real time performance and providing a warning in advance when the abnormal conditions are encountered in seakeeping performance. In general, seakeeping performance has been evaluated by simulating ship motion analysis under specific conditions for its design. However, due to restriction of computation time, it is not realistic to perform simulations to evaluate seakeeping performance under real-time operation conditions. This study aims to introduce a reasonable and faster method to predict a ship's roll motion which is one of the factors used to evaluate a ship's seakeeping performance by using a machine learning-based surrogate model. Through the application of various learning techniques and sampling conditions on training data, it was observed that the difference of roll motion between a given surrogate model and motion analysis was within 1%. Therefore, it can be concluded that this method can be useful to evaluate the seakeeping performance of a ship in real-time operation.

Key words : Seakeeping Performance, Roll Motion Prediction, Machine Learning, Surrogate Model, Korean e-Navigation

1. 서 론

최근 들어, 국내에서는 국제해사기구(IMO)의 e-Navigation 도입에 대응하여 우리나라 환경에 특화된 한국형 e-Navigation 서비스가 개발 중에 있으며, 이는 선박의 사고 방지와 운항의 합리성을 높이는데 그 목적이 있다. 해양안전심판원의 해양사고 통계에 의하면 최근 5년간(2013년~2017년) 국내 해양사고의 약 79.0%가 선박운항자에 의한 운항과실로 인해 발생하였으며, 상대적으로 운항환경이 열악한 연안여객선과 어선에 의한 사고가 70.0%를 차지하는 것으로 보고되고 있다(KMST, 2017). 이러한 경향으로 볼 때, 해양사고 예방을 위해서는 연

안해역을 운항하는 사고취약선박들에 대한 운항 중 안정성을 평가하고, 이상상태에 대하여 선박운항자의 의사결정을 지원할 수 있는 기술이 필요한 실정이다(IMO, 2005; IMO, 2008a; IMO, 2014; KMOF, 2016).

한국형 e-Navigation 서비스는 IMO에서 e-Navigation 구현을 위하여 규정한 16가지 MSPs(Maritime Service Portfolios)를 5가지 주요서비스(SV)로 재분류하였으며, 그중에서도 SV2 모듈은 실시간 운항정보 모니터링을 통해 해양사고의 발생을 차단하는 선내시스템 원격모니터링 서비스이다. 이 서비스는 항행 안전/화재 안전/내항성 안전의 3가지 모듈로 구성되어 있으며, 특히 내항성 안전 모듈은 사전 경보 체

† Corresponding author : 종신회원, jbpark@kmou.ac.kr 051)410-4233

* 정희원, kyl3982@gmail.com

** 종신회원, msbae@kmou.ac.kr 051)410-4280

(주) 이 논문은 “기계학습기반의 근사모형을 이용한 선박 횡동요 운동특성 예측에 관한 연구”란 제목으로 “2018년 한국해양과학기술협의회 공동학술대회 한국항해항만학회논문집(제주 국제컨벤션센터, 2018.5.24.-25, pp.41-42)”에 발표되었음.

계를 개발하여 사고를 사전에 방지하는 성격이 강하다 (KRISO, 2018).

내항성능이란 불규칙한 파랑 조건 속에서 예정된 항로 또는 해역을 안정적으로 운항할 수 있는 성능을 말한다. 통상적으로 내항성능의 평가는 선박 건조 시 IMO의 범규에 따라 복원성에 관한 설계 조건을 검토 및 승인하는 것으로 대체하거나, 필요시에는 선급의 해석지침에 따라 정해진 운동 조건에 대해서만 안정성을 검토하고 있다(ABS, 2005; DNV, 2013; IMO, 2008b; LR, 2009). 그러나 이러한 방법은 운항해역의 해상상태, 화물의 적재정도, 운항속도 등에 따른 선박의 내항성 변화를 실시간으로 평가하여 반영하기에는 한계가 있다. 선박의 운항 중 안정성을 모니터링하기 위하여 기존의 방법과 달리, Lee et al.(2005), Choi et al.(2007)는 3D 패널법을 이용한 내항성능 계산 결과를 데이터베이스화하는 방법을 제안한 바 있다. 데이터베이스 기반의 계산 방법은 선박의 적재조건, 홀수, 트림, 선속, 선수각 등의 조건이 일치하는 데이터베이스 값이 없을 경우, 해당하는 조건에 가장 근접한 값을 찾고 이를 보간하여 결과를 도출하는 과정을 거치게 된다. 하지만 이러한 방법은 각 변수들의 근사로 인하여 발생하는 결과의 오차, 다차원 보간으로 인한 계산의 복잡성과 같은 취약점이 존재하였으며, 향후 한국형 e-Navigation의 대상 선박들에 대한 확장성을 고려해 볼 때, 효율적이고 신뢰성 높은 내항성능 평가 방안에 대한 필요성이 제기되었다.

본 논문은 한국형 e-Navigation 서비스의 내항성 안전 모듈 연구의 일환으로 기계학습 기반의 근사모델(Surrogate model)을 활용하여 선박의 횡동요 운동을 예측하는 방법을 소개하고자 한다. 실제로 선박의 횡동요는 선체 형상, 크기 및 화물적재상태와 같은 선체요인, 선속 및 선수방위와 같은 운항 요인, 해상 및 기상상태와 같은 환경 요인 등 다양한 변수들에 의하여 영향을 받으며, 이러한 변수들을 고려한 선박의 운동특성을 파악하고자 근사모델을 활용하였다. 선박의 내항성 해석을 위한 운동해석은 3D 패널법을 사용하였으며, 그 해석 결과를 기계학습하여 근사모델로 이루어진 데이터베이스를 구축함으로써 실시간으로 변하는 외란에 대응하여 선박의 횡동요 운동특성을 즉각적으로 예측할 수 있는 모델을 구축하였다. 또한 다양한 기계학습 기법과 데이터 구성 조건에 따른 근사모델을 비교/분석하여, 선박의 횡동요 운동에 대한 단기 해석 예측 결과의 유효성을 검토함으로써 내항성능 근사모델 생성에 적합한 절차를 마련하고자 하였다. 향후에 이를 통해서, 한국형 e-Navigation의 내항성 안전 모듈은 선속, 선수각을 입력값으로 하는 기계학습기반의 근사모델로부터 예측한 횡동요 운동특성과 실시간으로 관측되는 횡동요 데이터를 상호 보완적으로 사용하여 선박의 내항성능에 대한 안정성을 평가할 계획이다.

2. 선박 횡동요 운동응답 근사모델

근사모델이란, 썬로게이트 모델(Surrogate model) 또는 메타모델(Metamodel)이라 불리며 실험 또는 시뮬레이션으로 얻은 데이터를 이용하여 실제 경향과 근접한 함수를 만드는 것을 일컫는다. 근사모델을 활용하면 해석이나 실험 또는 통계를 통한 추가적인 데이터가 없어도 물리적 거동을 상당히 정확하게 모사할 수가 있으며, 설계변수의 최적화 및 사이 값 확인 등 다양한 분야에 활용이 가능하다. 근사모델 생성에 사용되는 각 기계학습 기법들은 데이터의 크기, 변수의 개수, 잡음의 정도와 같은 데이터 특성에 따라서 예측 정확도나 연산속도가 좌우되기 때문에 해당하는 데이터의 특성에 대하여 어떠한 근사모델이 적합한 것인지 분석할 필요가 있다.

본 연구에서는 선체 운동해석으로부터 얻은 운동성능 데이터를 Datadvance사의 데이터분석 전문 소프트웨어인 pSeven의 기계학습 기능에 연동함으로써 선박의 횡동요 운동특성에 대한 근사모델을 구축하였다. pSeven은 사용자가 제공해주는 데이터를 기반으로 근사모델을 복잡한 수식의 형태로 생성해주는 프로그램이며, 다양한 수학 알고리즘을 내장하고 있어 데이터 특성에 맞는 학습기법 선정에 용이하여 선박 내항성능 예측에 적합할 것으로 판단된다(Belyaev et al., 2016a).

2.1 기계학습을 위한 데이터 정의

본 연구에서는 9600TEU급 컨테이너선을 대상으로 연구를 수행하였으며, 그 제원은 Table 1과 같다. Fig. 1은 선박의 운동계산을 수행하기 위하여 실측 크기를 기준으로 선체외관 형상을 3차원 패널로 모델링한 것이다.

Table 1 Principal particulars of the model ship

Particular	Model ship
LOA [m]	337
LBP [m]	320
Beam [m]	46
Depth [m]	27
Displacement [ton]	119927

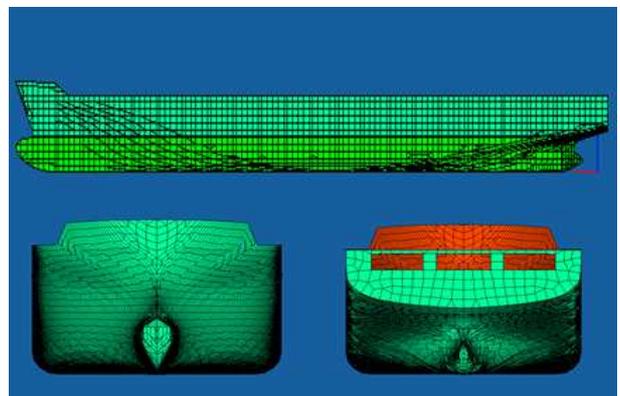


Fig. 1 Hull panel of the model ship

대상 선박의 선속, 선수각에 대하여 선체 운동해석을 수행하였고, 횡동요의 특성치인 횡동요 응답진폭함수(Response Amplitude Operator;RAO)를 결과로 취득하였다. 여기에서 선수각(Heading angle)은 좌의 진행 방향과 선박의 이동 방향이 이루는 각으로 정의한다. 학습을 통한 근사모형을 구현하기 위해 근사모형의 입력변수로 선속, 선수각 그리고 좌의 주파수를 선택하였으며, 출력변수는 횡동요 RAO를 지정하였다. 현재 연구에서는 선박의 속력을 바람 및 조류 등과 같은 환경 외란에 의한 증감분을 고려하여 선박 최대연속출력(Maximum Continuous Rating;MCR)의 110%까지인 20노트를 범위로 설정하였다. 또한 선수각은 0-180도, 좌의 주파수는 0.2-1.8 rad/s를 범위로 설정하였다. 운동해석은 로이드 선급의 3차원 포텐셜 이론 기반 프로그램인 WAVELOAD-FD를 사용하였으며, 해석 조건은 Table 2와 같이 매우 자세하게 수행하였다.

Table 2 Simulation cases for test data set

Ship speed (knot)	Heading angle (degree)	Wave frequency (rad/sec)
0 - 20	0 - 180	0.2 - 1.80
<i>(Interval : 1 knot)(Interval : 1 deg)(Interval : 0.04 rad/s)</i>		

일반적으로 기계학습을 위한 데이터 사용은 3가지로 분류된다. 하나는 학습을 통하여 근사모형을 생성하는데 사용하는 트레이닝 데이터 세트(Training data set), 그리고 학습도중 과적합(Overfitting)을 방지하기 위한 평가 데이터 세트(Validation data set), 마지막으로 학습에 사용되지 않은 데이터로 근사모형의 예측결과와 비교하여 모형의 정확성을 검증하는 테스트 데이터 세트(Test data set)가 있다. 본 연구에서는 최소한의 운동해석 결과로 실제 내항성능 평가에 적용 가능한 수준의 예측력을 가진 근사모형을 생성하는 것이 목적이기 때문에, 기존의 기계학습을 위한 데이터 분류 방법과는 달리, Table 2의 해석 결과로부터 대상 선박의 운동특성을 대표할 수 있는 정해진 조건의 데이터를 트레이닝/평가 데이터로 활용하고, 트레이닝/평가 데이터를 포함한 모든 해석 결과를 테스트 데이터로 활용하여 선박 운항 범위 내의 모든 운동 조건에 대하여 근사모형의 신뢰성을 검증하였다.

2.2 기계학습 기법 분석

Table 3은 기존에 여러 선급에서 선체 운동 및 강도 계산지침에 적용되는 해석 간격을 나타낸 것이다(ABS, 2005; DNV, 2013; LR, 2009). 선박 횡동요 데이터의 특성에 적합한 근사모형을 선택하기 위하여 Table 3의 선급 지침에 따른 선체운동 조건들을 충분히 포함하는 Table 4와 같은 조건을 구성하였고, Table 2의 시뮬레이션 결과에서 Table 4의 조건에 해당하는 결과를 취득하여 트레이닝 데이터를 구성하였다. 데이터의

학습을 위하여 모든 운동구간에 대한 선박의 운동해석 결과를 필요로 하기 때문에, 선속의 경우 Lloyd Register의 해석지침과 같이 선체 선속 범위를 균일한 간격(Section)으로 나누어 트레이닝 데이터를 취하는 방법을 선택하였다. 추출된 횡동요 RAO 데이터에 회귀분석법, 텐서근사법, 선형근사법 및 가우시안 프로세스의 기계학습 기법들을 적용하여 생성된 근사모형 예측 결과를 Table 2의 테스트 데이터와 비교하여 각 모형의 예측 적합성을 분석하였다.

Table 3 Classification guidances for ship's motion & strength analysis

Ship's classification	ABS	DNV	LR
Ship speed	Cb ≥ 0.7, 0 knot Cb < 0.7, 5 knot	2/3 of design speed	4 uniform section
Heading angle	15 degree increment	30 degree increment	20 degree increment
Wave frequency	0.05 rad/sec increment	0.05 rad/sec increment	0.04 rad/sec increment

Table 4 Sampling intervals for training data set

Case	Input variable			Output variable
	Ship speed (section)	Heading angle (degree)	Wave frequency (rad/sec)	
1	2	5	0.04	Roll RAO (rad/m)
2		30		
3	5	5		
4		30		

근사모형의 예측 정확성을 상호비교하기 위해 식 (1)의 결정계수를 사용하였다.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (1)$$

여기에서, y_i 는 테스트 데이터의 RAO, \hat{y}_i 는 근사모형에 의한 RAO 예측 값, \tilde{y}_i 는 테스트 데이터의 RAO 평균을 의미한다.

Table 5 Prediction accuracy of top four techniques

Case \ Tech.	GBRT	ITA	TGP	PLA
1	0.979	0.992	0.997	0.997
2	0.839	0.626	0.935	0.937
3	0.981	0.993	0.999	0.999
4	0.838	0.644	0.936	0.939

Table 5는 사용된 근사모델 중 Table 4의 학습 조건에서 예측 정확성이 높은 상위 4개를 나타낸 것이다. 각 학습기법별 근사모델의 적합도를 비교하면, GBRT(Gradient Boosted Regression Trees)와 ITA(Incomplete Tensor Approximation) 기법의 경우 트레이닝 데이터의 선수각 간격이 작은 조건에서는 높은 예측 정확도를 보이지만, 선수각 간격이 커지는 경우 정확도가 확연히 감소하는 것을 알 수 있다. 반면에 TGP(Tensored Gaussian process)와 PLA(Piecewise Linear approximation) 기법은 모든 샘플링 조건에서 적합도가 0.93 이상으로 상당히 높은 정확도를 유지하는 것을 알 수 있다. 가장 적합도가 높은 TGP와 PLA 기법의 정확한 비교를 위하여, Table 6과 같이 샘플링 조건을 세분화하여 검토하였다. Table 7은 Table 6의 조건에 따라 생성한 근사모델의 R^2 을 보여주며, Figs. 2-5는 이를 선속 간격 및 선수각 간격에 따라 나타낸 것이다.

Table 6 Sampling intervals for training data set

Case	Input variable			Output variable
	Ship speed (section)	Heading angle (degree)	Wave frequency (rad/sec)	
1	2	5	0.04	Roll RAO (rad/m)
2		10		
3		15		
4		30		
5	3	5		
6		10		
7		15		
8	4	30		
9		5		
10		10		
11		15		
12	5	30		
13		5		
14		10		
15		15		
16	5	30		

Table 7 Prediction accuracy of TGP & PLA models

Case \ Tech.	TGP	PLA
1	0.997	0.997
2	0.994	0.991
3	0.986	0.978
4	0.935	0.937
5	0.998	0.998
6	0.996	0.993
7	0.988	0.979
8	0.937	0.938
9	0.999	0.999
10	0.996	0.993
11	0.988	0.979
12	0.937	0.938
13	0.999	0.999
14	0.996	0.993
15	0.988	0.979
16	0.936	0.939

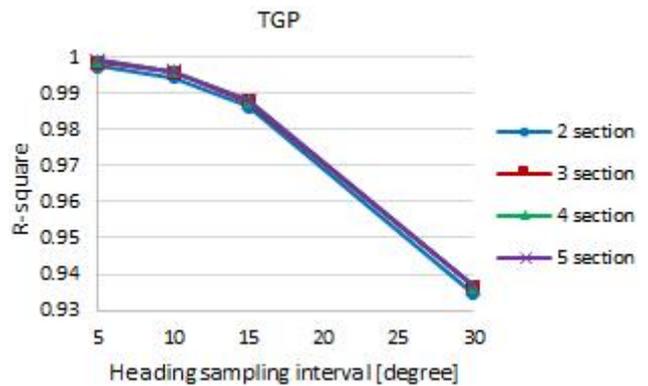


Fig. 2 R^2 of TGP model by heading sampling interval

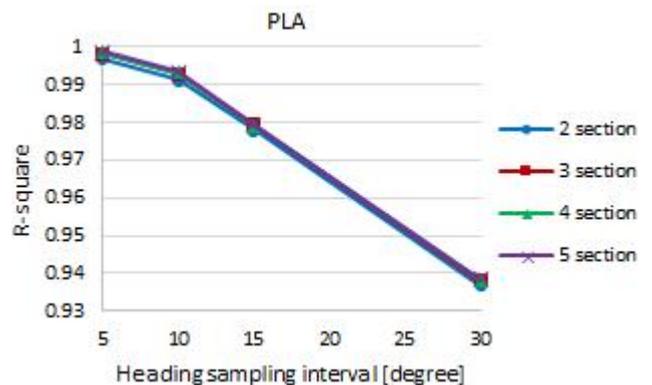


Fig. 3 R^2 of PLA model by heading sampling interval

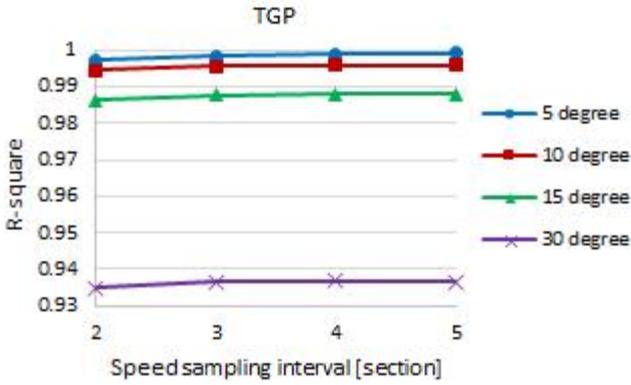


Fig. 4 R^2 of TGP model by speed sampling interval

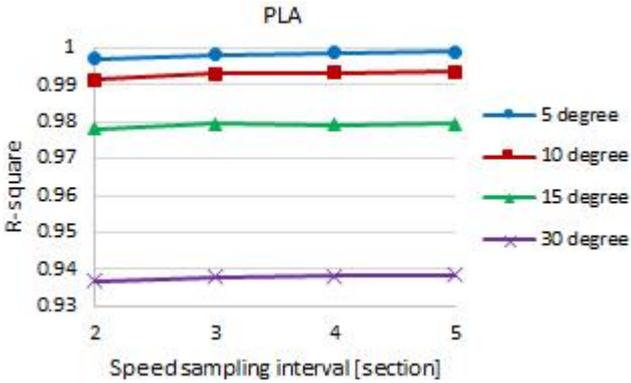


Fig. 5 R^2 of PLA model by speed sampling interval

Figs. 2-5와 같이 선속 및 선수각 간격에 따른 적합도를 비교하면, 공통적으로 선속의 데이터 샘플링 간격 변화에는 R^2 값이 크게 변하지 않지만 선수각의 변화에는 R^2 이 확연하게 차이나는 것을 알 수 있다. 이는 선박의 횡동요 운동특성이 선속의 변화에 대하여는 거의 일정한 경향성을 가져 일정 수준 이상의 선속 데이터만 확보되면 적합한 예측을 할 수 있는 반면, 선수각에 따라서는 그 운동특성의 변화가 크고 민감한 것으로 보인다. 또한 TGP 기법과 PLA 기법의 적합도를 나타낸 Table 7을 보면, 모든 비교 조건에서 두 기법은 거의 비슷한 예측 성능을 보여주는 것을 알 수 있다. 하지만 실용적인 측면에서 보면, TGP 기법은 고차원의 데이터 세트 계산에 효율적이어서 계산 결과를 빠르게 출력해주며, 컴퓨터 메모리 용량 면에서도 이점을 가졌다. 또한 트레이닝 데이터가 없는 구간에 대해서도 신뢰성 있는 예측이 가능한 기법으로 알려져 있어 본 연구의 목적상 실시간으로 선박의 횡동요 운동특성을 예측하기 위해서는 TGP 기법이 적합한 것으로 판단된다.

2.2.1 텐서 가우시안 프로세스

TGP 기법은 GP 모델을 보완하기 위하여 가우시안 프로세스에 텐서(Tensor)를 활용한 기법이다. 따라서 TGP 기법은 기본적으로 가우시안 프로세스의 알고리즘을 특성으로 하며, 트레이닝 데이터가 Fig. 6과 같은 요인배치법(Factorial

Design)의 형태에서만 구성될 수 있다(Belyaev et al., 2016a).

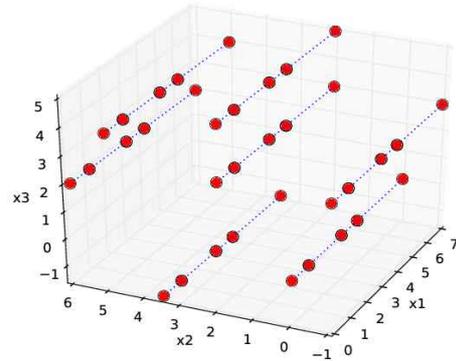


Fig. 6 Example of full factorization

본 연구에서 적용한 가우시안 프로세스의 특성은 다음과 같다. 가우시안 프로세스는 입력 데이터 x_i 의 집합 X 에 대한 출력 데이터 $f(x_i)$ 의 집합 $f(X)$ 로 표현할 수 있으며, 출력 데이터들은 가우시안 분포(Gaussian distribution)의 형태를 지닌다. 이러한 가우시안 프로세스는 식 (2)와 같이 평균 함수(mean function, $m(X)$)(식 (3))와 공분산 함수(covariance function, $k(X, X')$)(식 (4))로 정의할 수 있다. 공분산 함수 $k(X, X')$ 는 입력 데이터와 출력 데이터 간의 상관관계를 나타내며, 공분산 함수를 나타내기 위한 다양한 커널 함수들이 있다. 현재 연구에서는 보편적으로 많이 사용되는 커널 함수인 식 (5)의 제곱지수 커널(Squared exponential Kernel)을 활용한다(Cressie, 1992; Rasmussen and Williams, 2006).

$$f(X) \sim GP(m(X), k(X, X')) \tag{2}$$

$$m(X) = E[f(X)] \tag{3}$$

$$k(X, X') = E[(f(X) - m(X))(f(X') - m(X'))] \tag{4}$$

$$k(X, X' | a) = \sigma^2 \exp\left(-\sum_{i=1}^d \theta_i^2 (x^{(i)} - x'^{(i)})^2\right) \tag{5}$$

공분산함수 $k(X, X')$ 는 하이퍼 파라미터(hyper parameter) a 값에 의존하며, $a = \{\sigma, \theta_i, i = 1, \dots, d\}$ 에 해당한다. 하이퍼 파라미터는 가우시안 모델의 형태를 결정해주며, 공분산 커널 함수에 따라 그 종류와 개수가 달라진다.

트레이닝 데이터가 주어지면, 식 (6)-(7)을 통해서 가우시안 프로세스의 사후분포(posteriori distribution)를 추정할 수 있다. 특정한 X^* 에서의 사후분포 평균은 식 (6)과 같으며, 이는 모델의 예측에 사용된다. 또한 X^* 에서의 공분산함수는 식 (7)로 나타낼 수 있으며, 예측의 정확도 평가에 사용된다.

$$\hat{f}(X^*) = k^*(K + \tilde{\sigma}^2 I)^{-1} Y \tag{6}$$

$$V[\hat{f}(X^*)] = k(X^*, X^*) + \tilde{\sigma}^2 - k^*(K + \tilde{\sigma}^2 I)^{-1} (k^*)^T \tag{7}$$

여기에서, I 는 단위행렬, k^* 는 $k(X^*, X)$, K 는 $K(X, X)$ 를 나타낸다.

실제 데이터를 처리하는 경우 공분산 함수의 하이퍼 파라미터 a 는 보통 알 수가 없으며, 그 값을 추정하기 위하여 최대 우도법(Maximum Likelihood Estimation;MLE), 최대 사후 확률법(Maximum a Posteriori;MAP), 마코브 연쇄 몬테카를로법(Markov Chain Monte Carlo;MCMC)등 많은 방법들이 활용된다. 현재 연구에서는 식 (8)과 같이 해당하는 우도의 대수를 최대화하는 방법(MLE)을 적용하여 파라미터를 추정하였다(Burnaev et al, 2011).

$$\begin{aligned} & \log p(Y|X, a, \tilde{\sigma}) \tag{8} \\ &= -\frac{1}{2} Y^T (K + \tilde{\sigma}^2 I)^{-1} Y - \frac{1}{2} \log |K + \tilde{\sigma}^2 I| - \frac{|S|}{2} \log 2\pi \end{aligned}$$

여기에서, $|K + \tilde{\sigma}^2 I|$ 는 $K + \tilde{\sigma}^2 I$ 의 행렬식(determinant)이다.

근사모델 생성에 사용된 기계학습에 대한 자세한 내용은 참고 문헌[2, 3, 4, 5, 6, 8, 19]을 참조하기 바란다.

2.3 선급의 최소 샘플링 조건 분석

선박의 횡동요 운동 응답 근사모델 생성에 적합한 트레이닝 데이터 세트를 결정하기 전에, 기존의 선급 지침을 기준으로 한 근사모델의 타당성을 검토하였다. Table 8은 Table 3의 각 선급의 해석 지침에 나타난 입력변수들의 최소 샘플링 조건을 보여주며, 이 조건에서 TGP 기법의 근사모델을 생성하였다.

Table 8 Minimum sampling interval of classification guidances

Input variable			Output variable
Ship speed (section)	Heading angle (degree)	Wave frequency (rad/sec)	Roll RAO (rad/m)
4	15	0.04	

선박 운항 범위 내의 모든 선속 및 선수각 샘플링 조건에 대한 근사모델의 예측성능을 파악하기 위하여 R^2 외에 오차율을 적용하였다. 일반적으로 오차율은 참값에 대한 오차의 비로 정의되는데 선수파와 선미파 같이 횡동요 RAO 값이 0에 근사하는 경우, 기존의 오차율을 적용하면 분모에 의해서 계산이 불가하였다. 또한 본 연구의 목적상 응답이 큰 구간에서의 정확도 높은 예측이 중요하기 때문에, 식 (9)-(12)와 같은 수정된 오차율을 도입하였다. 식 (9)의 최대 RAO(Maximum RAO;Max.RAO)는 해석 구간 내의 각 선속구간에서 발생하는

최대 횡동요 RAO이며, 식 (10)의 수정된 오차율(Error rate;ER) 계산시 분모로 사용된다. 식 (10)은 각 선속 내의 가장 큰 응답을 기준으로 각 선수각 내의 주파수별로 발생하는 절대오차의 평균이 차지하는 비율을 나타냄으로써, 모든 해석 조건에서 오차의 비교를 용이하게 해준다. 식 (11)과 식 (12)는 오차율의 평균값(Average error rate;Ave.ER)과 최대값(Maximum error rate;Max.ER)을 나타낸다.

$$Max. RAO_i = \max [(y_{ijk})_{j=1 \sim m, k=1 \sim n}] \tag{9}$$

$$ER_{ij}(\%) = \frac{\frac{1}{n} \sum_{k=1}^n |\hat{y}_{ijk} - y_{ijk}|}{Max. RAO_i} \times 100 \tag{10}$$

$$Ave. ER(\%) = \frac{1}{l} \sum_{i=1}^l \left(\frac{1}{m} \sum_{j=1}^m ER_{ij} \right) \tag{11}$$

$$Max. ER(\%) = \max [(ER_{ij})_{i=1 \sim l, j=1 \sim m}] \tag{12}$$

여기에서, \hat{y} 는 근사모델에 의한 RAO 예측 값, y 는 테스트 데이터의 RAO 값, l 은 선속의 개수, m 은 각 선속에 포함되는 선수각 개수, n 은 각 선수각에 포함되는 주파수 개수이다.

Table 9 Prediction accuracy of model with minimum sampling interval

R^2	Ave. Error rate (%)	Max. Error rate (%)
0.988	2.16	18.15

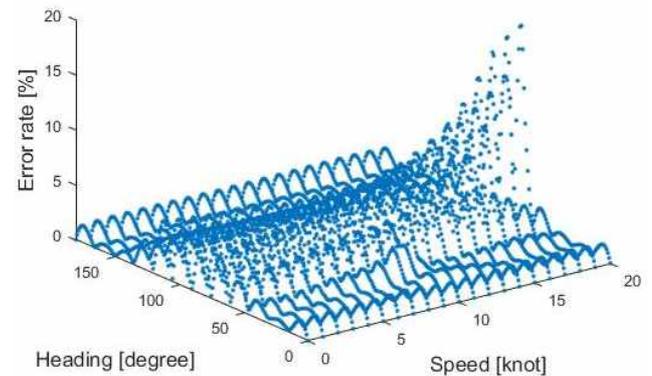


Fig. 7 Error rate by ship's speed and heading

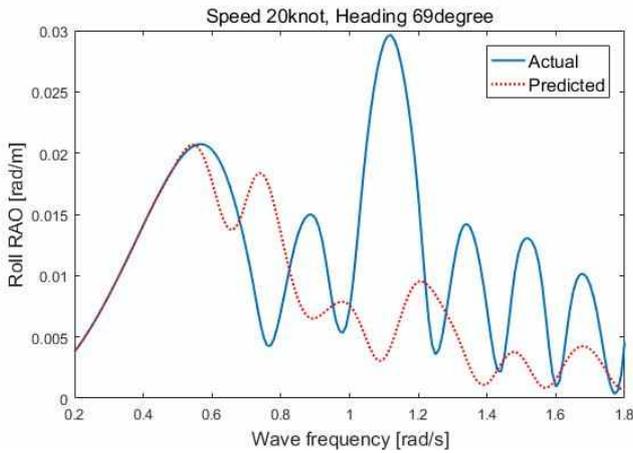


Fig. 8 Comparison of actual roll RAO and predicted roll RAO at maximum error rate

Fig. 7은 선급의 최소 샘플링 조건으로 생성한 근사모델의 각 구간 별 오차율을 나타낸 것이다. Table 9는 오차율을 정리한 것이며, 전체 테스트 데이터에 대한 평균 오차율은 2.16%, 최대 오차율은 선속 20노트, 선수각 69도에서 18.15%가 되었다. Fig. 8은 최대 오차율이 발생하는 조건에서 파의 주파수에 따른 횡동요 RAO 결과와 근사모델로 구한 예측결과를 비교한 것이다. 주파수 0.6 rad/s 이하에서는 예측 결과가 테스트 데이터와 거의 일치하지만, 0.6 rad/s 이상의 주파수 구간에서는 오차가 크게 나타남을 알 수 있다. 이러한 결과로 볼 때, 선급의 최소 샘플링 조건으로 생성한 근사모델은 R^2 값이 0.988로 모델 자체의 적합도는 상당히 높은 편이지만 선박의 주 운항 구간인 최대연속출력의 속도 50%이상, 선수각 60-120도에서 부분적으로 오차가 크게 발생하기 때문에, R^2 값만을 사용하여 선박의 실시간 횡동요 예측 샘플링 조건을 선정하기에는 다소 무리가 있을 것으로 판단된다. 따라서 운항 중 선박의 횡동요 예측 시스템으로 사용될 근사모델은 전체 운항 구간에 대하여 높은 정도를 제공해야 하는 것뿐만 아니라, 선박의 횡동요가 극심해질 수 있는 특정한 운동 조건에서의 예측 성능도 상당히 우수해야 하기 때문에, 전체 테스트 데이터에 대한 평균 오차율과 최대 오차율을 모두 적용하여 합리적인 샘플링 조건을 선정해야 한다. 따라서 Table 8보다 엄격한 샘플링 조건을 선정하여 합리적인 예측정도를 갖는 근사모델을 얻고자 하였다.

2.4 트레이닝 데이터의 샘플링 조건 및 오차율 판정기준 선정

Figs. 2-5의 결과로부터 횡동요 운동응답 근사모델은 동일한 조건에서 선속보다는 선수각의 학습데이터를 늘리는 것이 모델의 적합도 향상에 효율적임을 알 수 있다. 따라서 Table 10과 같이 선급 최소 샘플링 조건보다 엄격하게 선수각의 간격을 각각 15도, 10도 및 5도로 트레이닝 데이터를 구성하는 경우와 오차가 크게 발생하는 60-120도 구간에만 추가적으로 10도, 5도, 2도로 트레이닝 데이터를 구성하는 경우를 조합하

여 근사모델의 예측 정확성을 분석하였다. 근사모델의 적합도의 판정기준은 평균 오차율 1.3%이하, 최대 오차율 9.0%이하로 정하였다. 3장에서 이러한 오차율 판정기준을 만족하는 근사모델의 적합성을 검증하였고, 이러한 오차율 판정기준이 합리적인 횡동요 운동응답 근사모델을 선정하는데 부합하는 기준임을 입증하였다.

Table 10 Sampling intervals for training data set of alternative models

Case	Input variable			Output variable	Remark
	Ship speed (section)	Heading angle (degree)	Wave frequency (rad/sec)		
1	4	15	0.04	Roll RAO (rad/m)	
2		15			60-120(10)*
3		15			60-120(5)*
4		15			60-120(2)*
5		10			
6		10			60-120(5)*
7		10			60-120(2)*
8		5			
9		5			60-120(2)*

* : For 60-120 degree range, the heading interval of training data is composed of the numbers in parentheses.

Table 11 Prediction accuracy of alternative models

Case	Training data set	R^2	Ave. Error rate (%)	Max. Error rate (%)
1	2665	0.988	2.16	18.15
2	3075	0.995	1.55	11.53
3	4305	0.991	2.96	10.77
4	7995	0.995	2.11	9.37
5	3895	0.996	1.37	11.57
6	5125	0.998	1.00	7.50
7	8815	0.998	1.10	6.78
8	7585	0.999	0.69	7.44
9	11275	0.999	0.70	5.95

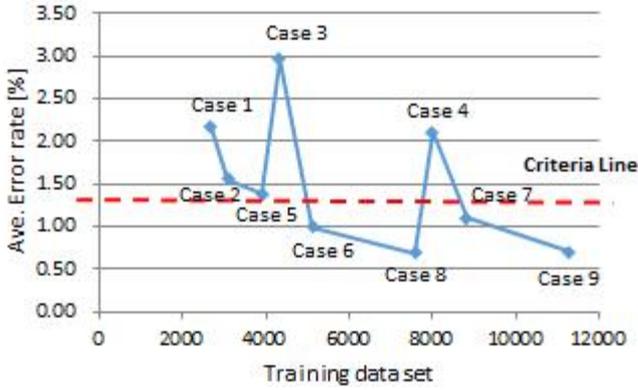


Fig. 9 Average error rate of alternative models by the number of training data set

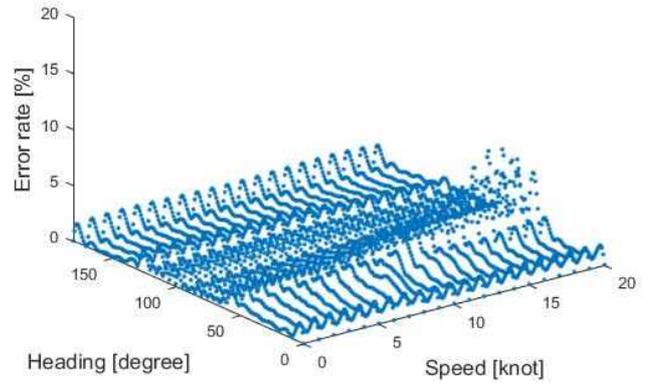


Fig. 11 Error rate by ship's speed and heading(Case 6)



Fig. 10 Maximum error rate of alternative models by the number of training data set

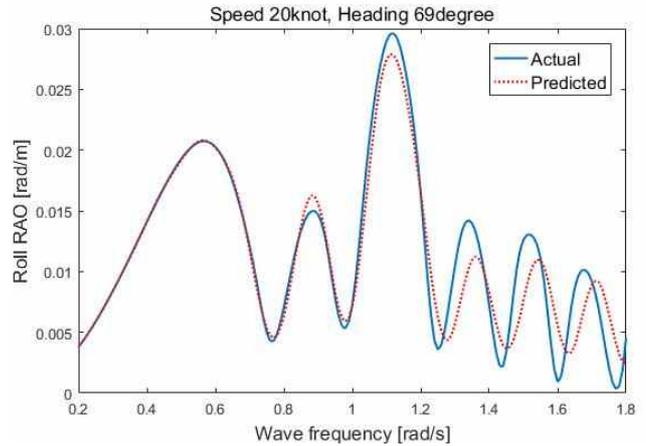


Fig. 12 Comparison of actual roll RAO and predicted roll RAO at maximum Error rate(Case 6)

Table 11은 Table 10의 샘플링 조건에 따라 사용된 트레이닝 데이터 개수, 생성된 근사모델의 예측 정확성 및 오차율을 나타내었으며, Fig. 9와 Fig. 10은 트레이닝 데이터 세트 개수에 따른 근사모델의 평균 오차율과 최대 오차율을 그래프로 나타낸 것이다. 평균 오차율과 최대 오차율에 대한 기준치를 만족하는 경우는 Case 6, 7, 8, 9이다. 트레이닝 데이터 세트 개수에 따른 모델의 오차율을 비교해보면, 데이터 세트가 5000개 이상에서는 근사모델의 평균 오차율과 최대 오차율이 크게 개선되지 않는 것을 알 수 있다. 따라서 현재 연구에서는 기준치를 만족하는 Case 중 가장 계산 효율이 좋은 Case 6으로 근사모델의 유효성을 검증하였으며, 이는 3장에서 다룬다.

Fig. 11은 Case 6의 조건을 적용하여 생성한 근사모델의 오차율을 나타낸 것이다. 평균 오차율은 1.00%로 기존의 선급 기준에 비해서 감소하였으며, 최대 오차율은 선속 10-20노트, 60-120도 구간에서 주로 발생하는 것을 알 수 있다. Fig. 12는 최대 오차율이 발생하는 조건에서 근사모델의 RAO 예측 값을 나타낸 결과이며, 전체 주파수 구간에서 테스트 데이터와 상당히 잘 일치하는 것을 알 수 있다.

3. 근사모델의 유효성 검증

주어진 해상상태에서 선박의 내항성능을 추정하기 위하여 단기해상상태에 대한 선박의 횡동요 극대치(Extreme value)를 활용하였다. 이를 위해 2장에서 선정된 근사모델로 횡동요 RAO를 예측하고, 식 (13)과 같이 파랑스펙트럼을 적용하여 응답스펙트럼을 구하였다. 식 (14)와 같이 적분하여 응답스펙트럼의 n차 모멘트를 구하였고, 이 중 m_0 와 m_2 를 이용하여 식 (15)의 단기해상상태에서 응답의 극대치를 구하여 근사모델의 유효성을 검증하였다.

$$S_R(w) = S(w) \times |RAO(w)|^2 \quad (13)$$

$$m_n = \int_0^\infty w_e^n S_R(w) dw \quad (14)$$

$$Q_p = \sqrt{2m_0 \ln \left(\frac{1800T}{\pi} \sqrt{\frac{m_2}{m_0}} \right)} \quad (15)$$

여기에서, w 와 w_e 는 파의 주파수와 선박의 조우주파수이며, $S(w)$ 는 파랑스펙트럼, $RAO(w)$ 는 선박의 w 에서 RAO, $S_R(w)$ 은 응답스펙트럼, m_n 는 응답스펙트럼의 n 차 모멘트, Q_p 는 단기해상상태에 대한 최대 응답값, T 는 해당 파랑스펙트럼에 노출된 시간(hour)을 나타내며, 본 계산에서 T 는 일반적으로 단기해상상태의 응답에 사용되는 3시간을 적용하였다.

3.1 파랑스펙트럼 결정

한국형 e-Navigation 내항성 안전 모듈에서는 선박 운항해역의 기상 정보를 기상청의 예보 데이터와 선박에 탑재된 풍향/풍속계 등으로부터 실시간으로 제공받을 예정이며, 이러한 정보를 2장에서 예측한 횡동요 RAO에 적용하여 선박의 횡동요 운동 응답스펙트럼을 계산한다. 일반적으로 파랑스펙트럼은 선박이 운항하는 해역의 특성과 시기에 따라 다를 수가 있기 때문에, 추후 실해역의 충분한 데이터 축적을 통해서 파랑스펙트럼의 적합성을 판정하고자 한다. 또한 파랑스펙트럼에 적용하는 해상 상태는 실제 운항 조건을 고려하여 선정되어야 하지만, 본 연구에서는 근사모델의 유효성을 검증하기 위한 목적으로 선박의 횡동요 RAO의 최대값이 빈번하게 발생하는 주파수 구간에서 다량의 에너지를 포함할 수 있는 해상 조건을 선정하였다.

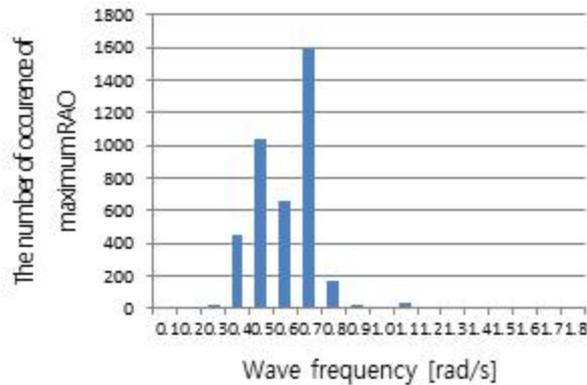


Fig. 13 Histogram of peak roll RAO

Fig. 13은 각 선속 및 선수각에서 최대 횡동요 RAO가 발생하는 주파수를 발생빈도별로 나타낸 Histogram이며, 이로부터 T_1 과 $\overline{H}_{1/3}$ 은 12.00 sec와 4.00 m로 설정하였다. 파랑스펙트럼은 식 (16)과 같이 ITTC 표준 스펙트럼인 Pierson-Moskowitz 스펙트럼을 사용하였으며, Fig. 14와 같다.

$$S(w) = \frac{A}{w^5} \exp\left(-\frac{B}{w^4}\right) \quad (16)$$

여기에서, $S_R(w)$ 는 선체운동응답스펙트럼, $S(w)$ 는 파랑스펙트럼, $RAO(w)$ 는 응답진폭함수, $A = 172.75 \overline{H}_{1/3}^2 / T_1^4$, $B = 691 / T_1^4$, w 는 파의 주파수, $\overline{H}_{1/3}$ 는 유의파고, T_1 는 파의 평균 주기를 나타낸다.

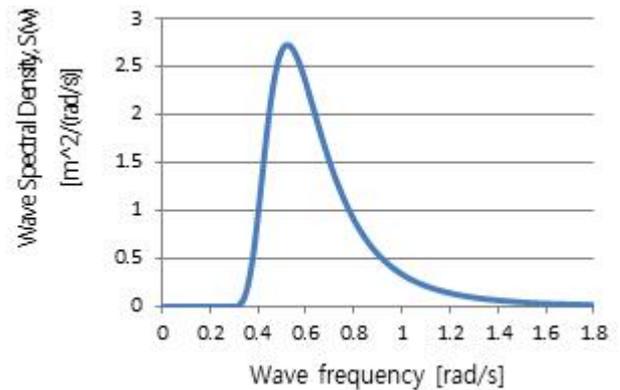


Fig. 14 ITTC wave spectrum

3.2 응답스펙트럼 예측

Fig. 15는 식 (13)을 이용하여 선속 20노트와 선수각 69도에서 근사모델로 얻은 횡동요 RAO 예측 값, $|RAO(w)|$,에 파랑스펙트럼, $S(w)$,을 합성하여 얻은 선체운동응답스펙트럼, $S_R(w)$,이며, 근사모델 예측 값이 테스트 데이터 결과와 매우 잘 부합하는 것을 알 수 있다. 고주파 구간에 대해서도 오차가 거의 발생하지 않는 것을 알 수 있는데, 이는 고주파 영역에서 파랑스펙트럼의 에너지가 상대적으로 작아서 횡동요 RAO의 오차에 비해 응답스펙트럼의 오차가 줄어든 것으로 볼 수 있다. Table 12는 해당하는 조건에서 m_0 , m_2 및 Q_p 값에 대한 예측 오차를 비교한 것이다. m_0 예측결과는 1.08%, m_2 는 1.94% 오차를 가지며, Q_p 의 오차는 0.57%로 상당히 높은 정확도를 갖는 것을 알 수 있다.

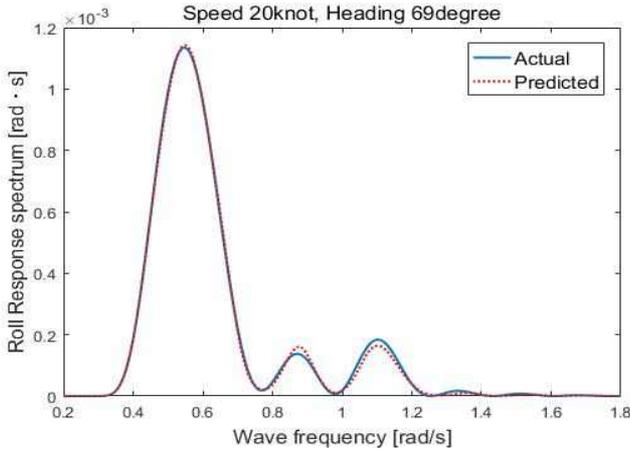


Fig. 15 Comparison of actual roll response and predicted roll response at maximum error rate

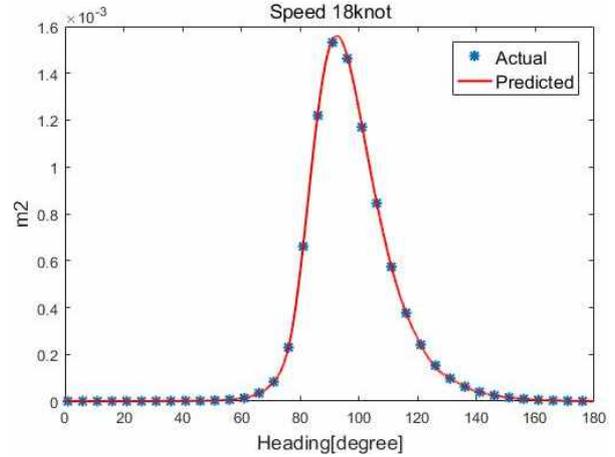


Fig. 17 Comparison of actual m_2 and predicted m_2 by ship's heading at 18knot

Table 12 Comparison of actual values and predicted values for m_0 , m_2 , Q_p at maximum error rate

	Actual value	Predicted value	Relative error rate
m_0	0.0002783 rad·s	0.0002753 rad·s	1.08%
m_2	0.0000617 rad·s	0.0000605 rad·s	1.94%
Q_p	3.498 degree	3.478 degree	0.57%

Fig. 16과 Fig. 17은 오차율이 많이 발생할 수 있는 선속 18노트에서 선수각에 따른 m_0 , m_2 예측 값을 테스트 데이터 결과와 비교하여 나타낸 것이다. 실선은 근사모델에 의한 예측 값이며, 별표로 나타낸 점들은 테스트 데이터에 해당한다. 모든 별표를 그래프의 실선이 통과하는 것으로부터 근사모델의 유효성을 확인할 수 있다. 또한 이러한 결과로부터 앞서 2장에서 제시한 근사모델의 오차율 판정기준이 적합함을 알 수 있다.

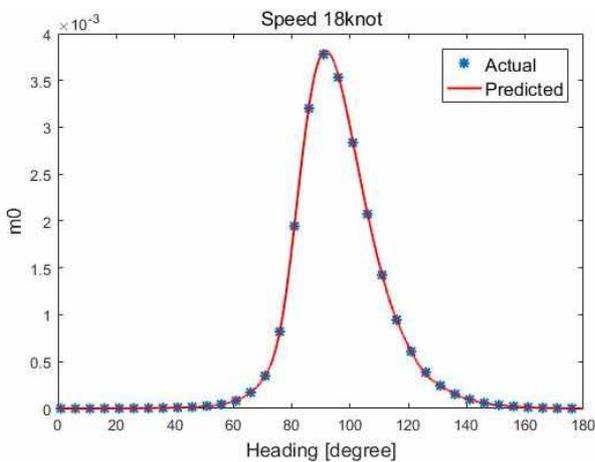


Fig. 16 Comparison of actual m_0 and predicted m_0 by ship's heading at 18knot

4. 결 론

본 논문은 한국형 e-Navigation 서비스의 내항성 안전 모듈 연구의 일환으로 기계학습 기반의 근사모델을 활용하여 합리적으로 선박의 횡동요 운동을 예측하는 방법에 대한 연구를 수행하였다. 내항성능 평가에 적용 가능한 정확도 높은 근사모델을 얻기 위하여 다양한 학습기법과 데이터 샘플링 조건에 따른 모델의 예측성능을 비교 분석하였으며, 이로부터 다음과 같은 결론을 얻었다.

(1) 선박 운동해석에 통상적으로 적용하는 데이터 샘플링 범위 내에서 기계학습 기법에 따른 근사모델의 예측 정확성을 비교한 결과, TGP 기법과 PLA 기법으로 학습한 근사모델의 예측 정확성이 가장 우수하였다. 기법의 특성과 실용적인 측면을 고려해볼 때, 빠른 연산이 가능한 TGP 기법이 선박의 실시간 내항성능 예측에 더 적합한 방법으로 선정하였다.

(2) 기존의 선급 해석 지침으로부터 데이터를 샘플링하여 근사모델의 타당성을 검토한 결과, 전체적인 모델의 적합도는 높았으나 특정 운항 구간에서 부분적으로 오차가 크게 발생하였다. 또한 횡동요 운동 데이터의 특성상 동일한 조건에서 선속보다는 선수각의 학습데이터를 늘리는 것이 모델의 적합도 향상에 효율적임을 알 수 있었다.

(3) 오차율이 큰 데이터 구간에 대해서 선수각의 샘플링 간격을 보완하는 다양한 샘플링 조건을 선정하였으며, 평균 오차율 1.3%이하, 최대 오차율 9.0%이하의 오차율 판정기준을 설정하여 다양한 샘플링 조건으로 생성된 근사모델의 예측 정확성을 판정하였다. 이로부터 Case 6 조건의 근사모델이 평균 오차율 1.0%, 최대 오차율 7.5%로 사용한 트레이닝 데이터 세트 개수 대비 내항성능 평가에 적합한 모델임을 알 수 있었다.

(4) Case 6 조건의 근사모델을 사용하여 횡동요 운동에 대한 단기해석을 수행하여 유효성을 검증한 결과, m_0 예측결과는 1.08%, m_2 는 1.94%, Q_p 는 0.57%의 오차로 우수한 예측 성능을 갖는 것을 알 수 있었다. 근사모델 특성상 빠르게 결과

값을 제공해주기 때문에, 해당하는 조건이 운항 중 선박의 실시간 내항성능 평가에 유용하게 사용될 수 있을 것으로 판단하였다.

향후 다양한 선종과 운항특성에 대한 추가적인 요인으로 선박의 흘수, 무게중심 및 선회반경 등을 반영하여 확장된 횡동요 운동응답 근사모델을 구축하는 연구가 필요할 것으로 사료된다.

후 기

이 논문은 2018년 해양수산부 재원으로 한국해양과학기술진흥원의 지원을 받아 수행된 연구이며(IMO 차세대 해양안전종합관리체계 기술개발), 특히 출원이 되었음(발명의 명칭 : 인공지능을 이용한 선박 운동 성능 예측 방법 및 시스템, 출원번호 : 10-2018-0111634).

References

- [1] American Bureau of Shipping(2005), "Guidance Notes on 'Safehull-Dynamic Loading Approach' for Container carriers".
- [2] Belyaev, M., Burnaev, E. and Kapushev, Y.(2015), "Gaussian process regression for structured data sets", Lecture Notes in Artificial Intelligence, Proceedings of SLDS, Vol. 9047, pp. 106-115.
- [3] Belyaev, M., Burnaev, E., Kapushev, E., Panov, M., Prikhodko, P., Vetrov, D. and Yarotsky, D.(2016a), "GTApprox: surrogate modeling for industrial design", Advances in Engineering Software, Vol. 102, pp. 29-39.
- [4] Belyaev, M., Burnaev, E. and Kapushev, Y.(2016b), "Computationally efficient algorithm for Gaussian Process regression in case of structured samples", Computational Mathematics and Mathematical Physics, Vol. 56, No. 4, pp. 499-513.
- [5] Burnaev, E., Zaytsev, A., Panov, M., Prikhodko, P. and Yanovich, Y.(2011), "Modeling of nonstationary covariance function of gaussian process using decomposition in dictionary of nonlinear functions", Information Technologies and Systems-2011, pp. 355-362.
- [6] Burnaev, E. V., Panov, M. E. and Zaytsev, A. A.(2016), "Regression on the basis of nonstationary Gaussian processes with Bayesian regularization", Journal of communications technology and electronics, Vol. 61, No. 6, pp. 661-671.
- [7] Choi, K. S., Park, M. K., Lee, J. H. and Park, G. I. (2007), "A study on the optimum navigation route safety assessment system using real time weather forecasting", Journal of the Korean Society of Marine Environment & Safety, Vol. 13, No. 2, pp. 133-140.
- [8] Cressie, N.(1992), "Statistics for spatial data", Terra Nova, Vol. 4, No. 5, pp. 613-617.
- [9] Det Norske Veritas(2013), "Classification Notes: CSA - Direct Analysis of Ship Structures".
- [10] International Maritime Organization(2005), "Development of an e-Navigation Strategy submitted by Japan, Marshall Islands, the Netherlands, Norway, Singapore, the United Kingdom and the United States", MSC 81/23/10.
- [11] International Maritime Organization(2008a), "Strategy for the Development and Implementation of e-Navigation - Report of the Maritime Safety Committee on its Eighty-fifth Session", MSC 85/26, Annex 20.
- [12] International Maritime Organization(2008b), "Adoption of the international code on intact stability, 2008 (2008 IS Code)", IMO Resoluituon MSC 267(85).
- [13] International Maritime Organization(2014), "Draft e-Navigation Strategy Implementation Plan - Report to the Maritime Safety Committee", NCSR 1/28, Annex 7.
- [14] Korea Ministry of Maritime Affairs and Fisheries(2016), "IMO Next-Generation Marine Safety Integrated Management System Development", Korean e-Navigation Project Notice No. 2016-01.
- [15] Korean Maritime Safety Tribunal(2017), Statistical annual reports from 2013 to 2017, Status of marine accidents' causes as per types and years, <https://www.kmst.go.kr/kmst/statistics/annualReport/selectAnnualReportList.do>
- [16] Korea Research Institute of Ships & Ocean Engineering(2018), "Implementation of Core Technology for Korean e-Navigation Services", Annual performance plan report.
- [17] Lee, J. H., Choi, K. S., Park, G. I., Kim, M. S. and Bang, C. S.(2005), "Basic Research of Optimum Routing Assessment System for Safe and Efficient Voyage", Journal of the Society of Naval Architects of Korea, Vol. 42, No. 1, pp. 57-63.
- [18] Lloyd's register of Shipping(2009), "Ship Right FDA level 3 procedures manual", technical planning and development department.
- [19] Rasmussen, C. E. and Williams, C. K.(2006), "Gaussian process for machine learning", MIT press.

Received 4 September 2018

Revised 4 December 2018

Accepted 6 December 2018