

Form Parameter 기법을 활용한 딥러닝 기반의 소형선박 초기복원성 계산에 관한 연구

A Study on the Initial Stability Calculation of Small Vessels Using Deep Learning Based on the Form Parameter Method

이동근¹, 오상진², 임채옥³, 김진욱⁴, 신성철^{5*}

Dongkeun Lee¹, Sang-jin Oh², Chaeog Lim³, Jin-uk Kim⁴, Sung-chul Shin^{5*}

〈Abstract〉

Approximately 89% of all capsizing accidents involve small vessels, and despite their relatively high accident rates, small vessels are not subject to ship stability regulations. Small vessels, where the provision of essential basic design documents for stability calculations is omitted, face challenges in directly calculating their stability. In this study, considering that the majority of domestic coastal small vessels are of the Chine-type design, the goal is to establish the major hull form characteristic data of vessels, which can be identified from design documents such as the general arrangement drawing, as input data. Through the application of a deep learning approach, specifically a multilayer neural network structure, we aim to infer hydrostatic curves, operational draft ranges, and more. The ultimate goal is to confirm the possibility of directly calculating the initial stability of small vessels.

*Keywords : Hull form, Form parameter, Deep learning model,
Hydrostatic curve modelling, Small ships*

1 주저자, 한국해양교통안전공단
E-mail: leedk@komsa.or.kr

2 부산대학교 조선해양공학과, 박사과정
E-mail: osj5588@pusan.ac.kr

3 부산대학교 생산기술연구소, 연수연구원
E-mail: orc@pusan.ac.kr

4 부산대학교 조선해양공학과, 석사과정
E-mail: jinwok97@pusan.ac.kr

5* 교신저자, 부산대학교 조선해양공학과, 교수
E-mail: scshin@pusan.ac.kr

1 KOMSA, Korea Maritime Transportation Safety Authority,
Republic of Korea

2 Dept. of Naval Architecture and Ocean Engineering, Pusan
National University, Busan, Republic of Korea

3 Research Institute of Industrial Technology, Pusan National
University, Busan, Republic of Korea

4 Dept. of Naval Architecture and Ocean Engineering, Pusan
National University, Busan, Republic of Korea

5* Corresponding Author, Dept. of Naval Architecture and Ocean
Engineering, Pusan National University, Busan, Republic of Korea

1. 서론

2018년 이후 5년간 480척의 연안선박 전복사고가 발생하였으며, 소형선박의 전복사고는 89%인 428척이 발생하였다[1]. 상대적으로 높은 전복사고 발생빈도에도 불구하고 소형선박은 감항성 평가와 밀접한 관계가 있는 선박복원성기준을 적용하지 않고 있으며, 복원성계산에 필요한 기초설계도서(일반배치도, 선체선도, 중앙단면도, 강재구조도 등)의 비치가 생략되어, 직접 복원성계산은 현실적으로 곤란한 실정이다.

소형선박의 선형특성 관련 연구는 저항성능과 복원성능 개선을 목적으로 하는 연구가 다수였으며, 소형선박의 Chine 형상과 관련된 연구는 대부분 고속선형의 저항성능 관점에서 성능개선을 목적으로 하는 연구[2]가 대부분이었으며, 일부 연구에서는 소형선박의 복원성능 추정 또는 소형선박 이외의 선박(24미터 이상 선박 등)의 복원성 기준의 준용에 대한 연구[3]가 있었지만, Chine의 분포에 따른 복원성능 변화에 대한 체계적인 연구는 상대적으로 소홀하였다. 따라서, 본 연구에서는 국내 연안 선박의 대부분이 Chine형 선박임을 감안하여, 일반배치도와 같은 한정된 설계도서에서 확인할 수 있는 선박의 주요 선형특성데이터를 입력 데이터로 설정하고, 인공지능기법의 하나인 다층신경망 구조의 딥러닝을 통한 Hydrostatic Curve 및 운항 흡수범위 등을 추론하여, 소형선박의 초기 복원성 직접계산 가능성을 확인하고자 한다.

2. 선박복원력 계산 및 배수량등곡선도

2.1 선박복원력 계산

선박의 복원력이란 평형상태에 있던 선박이 외




Fig. 1 Initial ship stability calculation

력에 의하여 경사되었을 때 다시 원래의 평형상태로 되돌아가려는 힘이며, 복원력은 선박의 무게중심, 배수량, 수선면의 형상에 대한 관성모멘트 등에 따라 크기가 결정되며, 경사시험을 실시하여 구하여진 선박의 무게중심(G)과 Hydrostatic Curve를 이용하여 계산한다.

초기복원력은 Fig. 1과 같이 선박의 미소 횡경사각(ϕ)에 대응하는 복원모멘트와 같다.

$$\text{복원력} = W \times \overline{GZ} = W \times \overline{GM} \times \sin \phi$$

여기서,

$$\begin{aligned} \overline{GM} &= \overline{KM} - \overline{KG} = \overline{KB} - \overline{BM} - \overline{KG} \\ &= \overline{KB} + \frac{I_t}{\nabla} - \overline{KG} \end{aligned}$$

W: 배수량, ∇ : 배수용적, I_t : 단면 관성모멘트,

M: 횡메타센터위치, B: 수선하부 부피중심,

G: 무게중심

2.2 배수량등곡선도

Hydrostatic Curve는 선박의 흡수변화에 대한 배수량의 변화를 계산하고, 이들 배수량에 대응하는 선박의 유체정역학적 특성값의 분포를 나타내는 곡선(또는 수치표)이다. 이들 특성값에는 흡수별 배수량, 수선하부 용적의 부피중심, 수선면의 면적 및 침수표면적, 방형계수 등을 포함한 각종

선형계수들이 포함되며, 선박복원력 계산의 필수 자료이다.

3. 딥러닝 학습 데이터 구성

본 연구에서는 Hydrostatic Data를 계산할 수 있는 402척으로 학습데이터를 구성하였으며, 일반적인 추진시스템인, 내연기관 및 나선추진기에 의하여 추진되는 선박으로 한정하였다. Hydrostatic Data 계산은 Box Keel을 포함한 주선체만 계산하였으며, 현측부기물, 선미부력부 및 선수별브 등과 같은 일체의 부기물은 계산에 포함하지 않았다.

3.1 학습데이터 무차원화

딥러닝의 입력데이터(Feature Data)는 일반배치 도에서 확인 가능한 주요치수비와 상갑판, Chine 및 Box Keel 데이터 등의 주요선형특성데이터로 무차원화하여 구성하였다.

무차원화된 학습데이터는 딥러닝의 높은 학습효과와 데이터 상호비교가 직관적으로 가능하며, 매개변수(Parameter)로 활용가능한 장점이 있다. 선박의 길이, 너비, 깊이 방향의 offset 좌표는 각각

Table 1. Range of dimensionless data

Feature Data(Unit)	무차원 계수	'0' 기준	
Offset Data (m)	길이방향(x)	L_T (상갑판길이)	선미단
	폭방향(y)	B_m (형너비)	중심선
	깊이방향(z)	D_m (형깊이)	기선
Volume(m^3)	$L_T \times B_m \times D_m$ (체적수)	-	
KB(m)	D_m (형깊이)	기선	
It(m^4)	$L_T \times B_m^3 / 12(I)$	-	

선미기점(Aft. End), 선체중심선(Center Line) 및 기선(Base Line)을 기준으로 0과 1사이의 무차원 값으로 변환하였고, Hydrostatic Data의 항목별 차원인 면적, 체적, Moment of Inertia 등의 데이터는 각각 대응하는 선박 특성값의 비율로 Table 1과 같이 무차원화하였다.

3.2 딥러닝 학습 범위 설정

선박의 실제 운항 흘수범위는 경하상태에서 만재상태까지로 가정할 수 있으며, 학습데이터의 적재상태(경하 및 만재상태)별 흘수분포는 Fig. 2와 같다.

사분위수(Quartile)를 통한 통계적 이상치(Outlier) 식별 방식¹⁾을 적용하여 경하 및 만재 적재상태별 이상치를 제외한 흘수 범위는 0.28~0.90Dm 이며, 본 연구에서는 소형선박의 실제 운항형태를 반영하고, 딥러닝 학습 정확도를 높이기 위하여 학습의 범위를 0.28~0.90Dm으로 설정하였다.

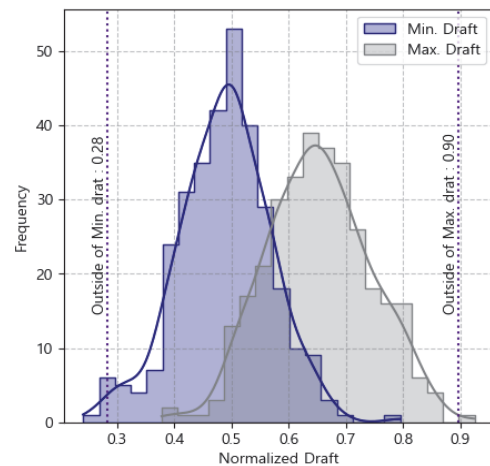


Fig. 2 Distribution of Min. & Max. draft

1) $1.5 \times IQR$ (Inter Quatile Range)

3.3 디러닝 입력데이터

학습에 사용한 입력데이터는 Table 2과 같이 3개의 주요치수비 및 일반배치도로부터 확인가능한 18개의 주요선형특성 Offsets과 주요선형특성치 (Chine, Sheer 등)와 총톤수 및 주요치수 등으로 구성하였다.

Table 2. Hull form feature data

항목	구성	No.
주요치수비	L/B, B/D, L/D	3
선형특성치	선수·미 Sheer Height 등	2
상갑판 Offset	선수·미, 중앙부,	4
Chine Offset	중앙평행부 등	4
Box Keel Offset	선수·미, 중앙부, 최대폭 등	4

3.4 디러닝 출력데이터

Hydrostatic Data의 분포형상은 주요치수 및 치수비, Chine 형상 등과 같은 선박의 주요선형특성 데이터와 밀접한 관련이 있으며, Hydrostatic Data의 기하학적 특성을 규정하는 Form Parameter들을 결합하여 수학적 모델로 변환하면, 주요선형특성 데이터와 Form Parameter의 상관관계를 추론할 수 있다. 본 연구에서는 연속형 수치데이터로 구성된 Hydrostatic Data를 Form Parameter를 이용한 수학적 모델로 변환하여 디러닝의 출력(Target) 데이터로 설정하였다.

3.4.1 Form Parameter를 이용한 수학적 모델링

Form Parameter 방법은 다양한 형태의 형상데이터를 수학적으로 표현하기 위하여, 형상의 특성을 나타내는 기하학적 크기인 Form Parameter들을 적절히 조합하여 수학적 모델로 변환하는 방법

이다. 기하학적 특성을 정의하는 Form Parameter들은 점(위치), 미분형(기울기, 곡률), 적분형(면적, 도심) Parameter로 이루어진다[4].

Hydrostatic Data는 복원성계산 프로그램(K-SHIP)을 활용하여 계산하였고, 홀수변화에 대응하는 연속형 수치분포형태의 데이터(Hydrostatic Data)로 출력되며, 초기복원성 계산에 필요한 홀수별 수선하부의 선체용적(Volume), 부심위치(KB), 단면2차모멘트(Moment of Inertia)에 대하여 수학적 모델링을 하였다. Hydrostatic Data를 2차 및 3차의 다항함수(Polynomial Function)의 조합 또는 선형함수(Linear Function)의 조합으로 설정하여 Form Parameter를 계산하였으며, 이들 수학적 모델과 실제 값의 오차를 비교하여 수학적 모델의 적합성을 확인하였다.

3.4.2 Volume & KB 데이터 수학적 모델링

Volume Data의 분포는 Fig. 3과 같이 홀수(x)에 대한 2차 이상의 다항함수로 근사할 수 있는 곡선 형태이다. Volume Data에 대한 B-Spline Curve Fitting(Order=3)을 실시하였으며, 일반적으로 0.5Dm ($x = 0.5$)부근에서 Fitting 곡선의 기




Fig. 3 Mathematical modeling of volume curve

울기가 $f'(x) \approx constant$ 인 구간이 발생하는 것을 확인하였다.

이러한 특성은 Chine Height의 분포 위치에 따라 발생하는 구간으로 추정되며, 일반적으로 $x = 0.5$ 를 기준으로 Volume Curve의 특성이 변화하는 것을 확인할 수 있었다. 본 연구에서는 수학적 모델의 정확성과 학습의 효율성을 높이기 위하여 $x = 0.5$ 를 수학적모델링 분할 경계(Segment Split Point)로 설정하였으며, Volume Data를 2개의 Form Parameter 기반의 다항함수(Polynomial Curve) 결합형태로 Fig. 3과 같이 수학적 모델링을 하였다.

$$Volume\ Data \approx f(x) \begin{cases} f_f(x) & 0.0 \leq x \leq 0.5 \\ f_a(x) & 0.5 < x \leq 1.0 \end{cases}$$

B-Spline Fitting 곡선으로부터 양단 경계점 및 분할점에서 위치 및 미분형 Form Parameter ($f(x), f'(x)$)를 계산하였고, 분할점($x = 0.5$)에서 C^1 연속(미분가능) 결합조건[5]을 적용하여 3차 및 2차 다항함수의 전·후반부 분할곡선으로 모델링하였다.

KB data도 동일한 방법으로 수학적 모델링 하였으며, 수학적 모델과 Volume 및 KB Data의 MAE(Mean Absolute Error) 및 MAPE(Mean Absolute Percentage Error), R^2 (R Squared Score) 등을 계산하여 변환의 적합도를 평가하였다.

3.4.3 It 데이터 수학적 모델링

It Data는 수선면(Wateplan)의 길이방향 중심축에 대한 단면2차모멘트(Transverse Moment of Inertia, m^4)이고, 선박의 초기복원력을 결정짓는 횡메타센터(Transverse Metacenter)의 높이에 많은 영향을 준다. 소형선박은 대부분 비교적 낮은

Chine Height와 배의 너비에 가까운 넓은 Chine 폭을 가지는 선형으로서, 기선(Base Line)으로부터 Chine Height까지의 흡수변화에 따른 수선면 형상 변화가 급격하게 발생하는 특징이 확인되었다. 학습에 사용된 Data Sets의 Chine Height 변화에 따른 It Data의 변화과정은 크게 4가지 변화 단계로 조사되었다.

It Data의 변화 단계는 선저 구배로 인하여 기선에서 중앙부 Chine Height 부근의 높이까지 수선면 형상의 급격한 변화로 발생하는 비선형 구간(Part ①)과 이후 Chine Max. Breadth Height 부근까지 선형적으로 변하는 구간(Part ②), 그리고 선미 Chine Height 부근까지의 비선형 구간(Part ③) 및 최종 선수 Chine Height 위치에 영향을 받는 선형구간(Part ④)으로 구분할 수 있는 것으로 파악되었다.

본 연구에서는 소형선박의 운용 흡수 범위를 고려하여 초기 비선형 구간(Part ①)은 제외하였고, 나머지 구간의 It Data를 선형근사(Linear Approximation)기법을 적용한 세 개의 구간직선(Fore, Mid., End Line Segment)의 조합으로 단순화하여 Fig. 4와 같이 수학적 모델링하였다. Chine

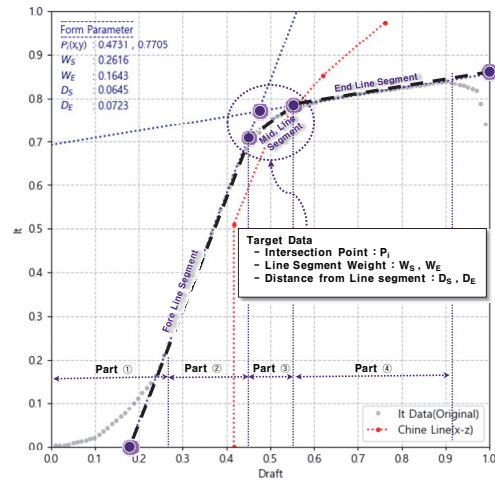


Fig. 4 Mathematical modeling of It curve

의 분포에 따라 이들 구간직선(Line Segment)의 기울기와 위치가 다양하게 변화하는 경향을 확인하였으며, 구간직선의 기하학적 분포 특성을 고려하고 수학적 모델의 구성을 단순화 하기 위하여, 구간직선(Fore, End Line Segment)의 교점(P_{ix} , P_{iy}), Weight(W_s , W_E) 및 중앙부 세그먼트와 교점 거리(D_s , D_E)로 선형근사 수학적 모델의 Form Parameter를 구성하여 학습데이터로 사용하였다.

3.4.4 수학적 모델링 결과

수학적 모델의 유효성 검증을 위한 오차계산은 회귀모델(Regression Model)의 성능 평가지표로 많이 사용되는 MAPE(Mean Absolute Percentage Error), MAE(Mean Absolute Error)를 활용하여 Table 3과 같이 계산하였다.

MAPE 및 MAE, R^2 등은 예측한 모델의 정확도를 평가하는 대표적인 성능지표로서 n개의 데이터에 대하여 실제값(y_i)에 대한 모델의 예측값($f(x_i)$)에 대하여, MAE는 모든 오차의 절대평균을 나타내고, MAPE는 절대오차의 실제값에 대한 백분율(%)의 평균을 나타내며, R^2 모델의 독립변수가 종속변수를 얼마나 잘 표현할 수 있는지 나타내는 지표이며 아래식과 같이 정의 된다[6].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - f(x_i)|$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - f(x_i)}{y_i} \right| \quad (y_i \neq 0)$$

$$R^2 = \sum_{i=1}^n \left(\frac{f(x_i) - \bar{y}}{y_i - \bar{y}} \right)^2 = 1 - \sum_{i=1}^n \left(\frac{y_i - f(x_i)}{y_i - \bar{y}} \right)^2$$

수학적 모델의 MAPE(%)는 0.87~1.10%이며, 일부 Data Set에서 MAPE 최대치가 4.97~12.77%의 오차를 보였지만, MAPE 계산의 특성상 실제값(y_i)이 0에 가까울수록 MAPE 계산값이 무한대로 발산(Divergency)하는 성질에 기인하는 것으로 판단된다. 실제(Real) Hydrostatic Data(MAE^R) 및 무차원화(Dimensionless) Hydrostatic Data(MAE^N)에 대한 평균 절대 오차인 MAE를 계산하였다. Volume Data의 실제 값에 대한 MAE^R의 전체 평균은 약 0.1(m³)로 계산되었고, 최대 0.4(m³)의 오차가 발생하였으며, KB Data의 MAE^R는 최대 약 0.006(m)까지 오차가 분포하였고, 전체 평균은 약 0.002(m)로 계산되었다. It Data의 실제 값에 대한 MAE^R의 전체평균은 약 0.306(m⁴)으로 계산되었으며, 최대 약 4.837(m⁴) 까지 오차가 분포하였다.

수학적 변환모델의 MAPE(%) 분포는 Fig. 5와 같으며, 약 1% 부근에서 분포밀도가 집중하는 것

Table 3. Statistic of mathematical modeling errors

Hydro. Data 오차 통계량	Volume Curve				KB Curve				It Curve				
	MAPE (%)	MAE ^N (-)	MAE ^R (m ³)	R ² (-)	MAPE (%)	MAE ^N (-)	MAE ^R (m)	R ² (-)	MAPE (%)	MAE ^N (-)	MAE ^R (m ⁴)	R ² (-)	
평균	0.96	0.0021	0.1119	0.9963	1.10	0.0024	0.0022	0.9968	0.87	0.0046	0.3056	0.9876	
표준편차	0.64	0.0011	0.0715	0.0037	0.62	0.0011	0.0010	0.0032	1.20	0.0041	0.3874	0.0262	
최소값	0.08	0.0002	0.0091	0.9789	0.19	0.0006	0.0006	0.9765	0.07	0.0005	0.0230	0.5754	
사분위수	25%	0.50	0.0012	0.0571	0.9947	0.72	0.0016	0.0015	0.9962	0.32	0.0022	0.1011	0.9871
	50%	0.86	0.0022	0.1014	0.9974	0.99	0.0022	0.0021	0.9978	0.51	0.0034	0.1940	0.9942
	75%	1.32	0.0028	0.1474	0.9990	1.33	0.0029	0.0027	0.9988	0.91	0.0053	0.3576	0.9978
최 대 값	3.83	0.0058	0.3839	1.0000	4.97	0.0069	0.0064	0.9998	12.77	0.0450	4.8369	0.9999	

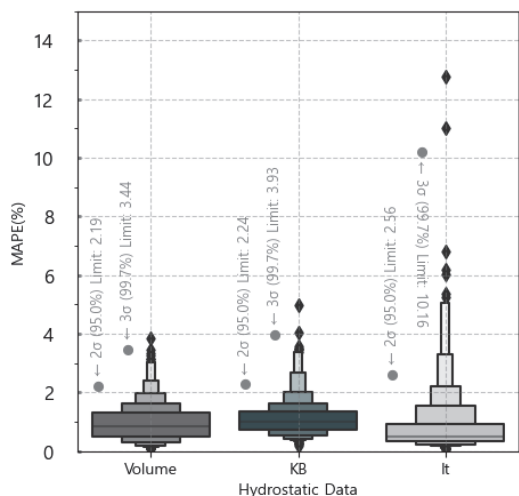


Fig. 5 Distribution of mathematical modeling MAPE(%)

을 직관적으로 확인할 수 있으며, 분포밀도가 0에 근접해야되는 오차분포의 특성을 고려할 때 양호한 형태인 것으로 판단된다. MAPE의 최대치에 대한 이상치 등을 평가하기 위하여 정규분포를 가정하여 검토할 경우, 일부 Data Set의 MAPE 값은 통계적 이상치로 분류할 수 있는 분포이며, 통계적 경험규칙을 준용하여 검토하였다. 표준편차(σ)의 2σ 상한(95%)은 각각 Volume, KB 및 It Data에 대하여 최대 2.19%, 2.24% 및 2.56%의 오차율이며, 3σ 의 상한(99.7%)은 최대 3.44%, 3.93% 및 10.16%인 것으로 계산되었으며, 2σ 및 3σ 범위에서 전체 평균 MAPE는 각각 2.33% 및 5.84%이며, 최소 97.67%와 94.16% 이상의 일치율을 보이는 것으로 계산되었다. 수학적 모델의 전체 MAPE 평균은 0.98%이며, 수학적 모델이 원시 데이터 대비 평균 약 99%의 일치율을 보이는 것으로 계산되었다.

회귀모델의 변수간 인과관계의 정도를 정량화하여 표현하는 결정계수인 R^2 는 독립변수가 종속변수를 얼마나 잘 나타내고 있는지 평가하는 계수로서 [0~1]의 값으로 계산되며, R^2 가 1에 가까울수록

회귀모델의 독립변수가 종속변수에 대한 높은 상관도를 가진다고 할 수 있다. It Data의 경우 다수의 구간직선 조합의 수학적 근사모델에 따라 상대적으로 낮은 R^2 의 분포가 일부 계산되었지만, 수학적 모델의 R^2 전체평균은 0.9936으로 계산되었다.

이상과 같이 다양한 평가지표를 사용하여 수학적 변환모델의 오차율을 종합 검토하였으며, Form Parameter를 이용한 수학적 모델의 정확도는 전반적으로 양호한 것으로 판단하고, 딥러닝의 학습 데이터로 활용하였다.

3.5 학습데이터 정규화

학습데이터의 다양한 수치범위 차이로 인한 왜곡효과를 최소화하고, 학습의 효율과 정도를 높이기 위하여 Data Scaling을 실시하였다. 학습모델이 특정 데이터에 의존하는 편향성을 방지하고 활성화함수의 Weight 및 Bias의 변동범위를 일정한 수준으로 유지할 수 있도록 아래와 같이 정규화²⁾(Normalization)를 실시하였으며, 본연구에서 구성한 딥러닝에서 양호한 학습결과를 확인하였다.

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

4. 딥러닝 모델 구성 및 학습결과

4.1 딥러닝 모델 구성

딥러닝 모델의 생성, 학습을 위하여 오픈소스 라이브러리인 Tensorflow의 상위수준 API인 Keras

2) Min-Max Scaling : 모든 Feature Data가 [0,1] 사이에 위치하도록 데이터를 변환한다.

Model을 사용하였으며, 데이터 전처리 및 수치연산, 학습의 평가 등은 Python 기반의 Pandas 및 Numpy, Scikit-learn Module 등을 활용하였다.

학습데이터의 일반배치도에서 확인 가능한 18개의 선형특성 Offset Data와 주요치수비 등을 딥러닝의 입력데이터인 Feature Data로 설정하였으며, 수학적 모델링과정에서 계산된 Form Parameter와 최소 및 최대 운항 흘수를 출력데이터인 Target Data로 설정하여 딥러닝 모델을 Fig. 6과 같이 구성하였다.

학습데이터(Train Data)와 검증데이터(Test Data)의 분할비율(Split Ratio)은 10%로 설정하여 Random하게 추출하였으며, 모델에 사용된 활성화함수(Activation function)는 회귀모델에 적합한 sigmoid, elu(Exponential Linear Unit), tanh(Hyperbolic Tangent) 및 relu(Rectified Linear Unit)를 사용하였다. 학습모델의 학습율(Learning Rate) 및 학습횟수(Epoch), 은닉층(Hidden Layer), Node의 구성과 연결방식 등은 Hyper-Parameter Tuning을 통하여 최적의 값으

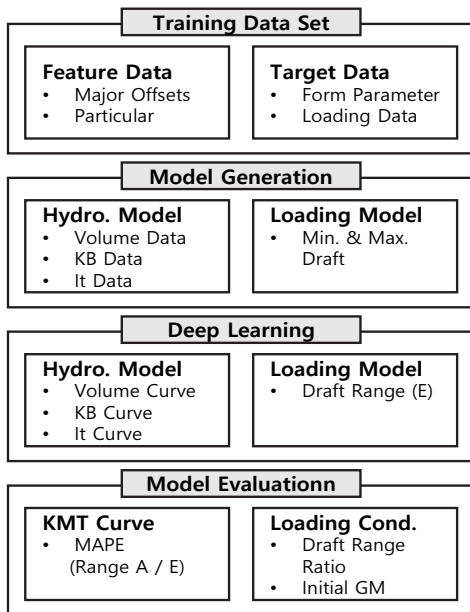


Fig. 6 Scheme of deep learning model

로 결정하였다.

복원력 계산을 위한 Hydrostatic Data인 Volume, KB, It Data와 각 선박의 운항흘수 범위에 대한 딥러닝 모델을 구성하여, 전체 학습범위의 운항 흘수구간(Range A)과 추론된 개별선박의 운항 흘수구간(Range E)에 대하여 수학적 모델과 실제값의 오차를 계산하여 모델의 정확도를 검증하였다.

4.2 딥러닝 Model 학습 결과

정량적 비교가 곤란한 Form Parameter의 데이터 특성을 고려하여, 딥러닝 학습결과에 대한 평가는 검증데이터(Test Data)와 예측데이터(Predict Data)의 MAE와 검증데이터의 Form Parameter별 실제 평균 값에 대한 오차(MAE)의 비율(%)로 평가하였으며, 최대 및 최소흘수에 대한 학습결과는 검증데이터의 흘수 범위에 대한 예측데이터의 중첩율로 평가하였다.

딥러닝 모델에 의한 Form Parameter의 추론결과는 Fig. 7과 같이 분포하였으며, Chine 변화에 대하여 비교적 일정한 패턴으로 변화하는 Volume




Fig. 7 Target data(form parameter) learning result

및 KB Data의 Form Parameter는 Equal Line ($y = x$)에 학습결과가 밀집하는 경향이 높고, 비교적 낮은 MAE Rate(%)이 계산되었다. 그러나, Chine 형상 변화에 민감도가 높은 It Data는 Equal Line에 대한 밀집도가 상대적으로 낮고, MAE Rate(%)이 높은 것을 확인하였다.

예측데이터의 MAE 전체 평균은 0.0229이며, 검증데이터 표준편차의 전체 평균(0.0699) 대비 약 32.52%를 유지하는 것으로 계산되었고, MAE Rate(%)의 전체 평균은 약 8.75%로 계산되었다. 흡수별 분포형태가 비교적 일정한 패턴을 보이고 다항함수 결합의 수학적 모델을 구성한 Volume 및 KB Curve의 Form Parameter는 비교적 양호한 학습결과를 보였고, 다수의 Line Segment로 선형근사(Linear Approximation) 결합의 수학적 모델인 It Data의 Form Parameter는 상대적으로 낮은 학습결과가 나타나는 것을 Table 4에서 확인할 수 있었다.

각 선박의 통상 운항범위를 나타내는 최소 및 최대 흡수범위(Range E)에 대한 학습 결과는 Fig.

Table 4. Distribution of form parameter MAE & MAE rate(%)

Form Parameter	Test Data		Predict Data			
	Mean	Std. Dev.	Mean	Std. Dev.	MAE	MAE Rate (%)
Volume	0.4071	0.0502	0.4101	0.0506	0.0137	7.59
KB	0.5431	0.0705	0.5378	0.0655	0.0181	3.25
It	0.3235	0.0859	0.3165	0.0802	0.0346	14.29

Table 5. Distribution of draft range MAE & MAE rate(%)

Items Draft	Mean		MAE	MAPE (%)
	Test Data	Predict Data		
Min.	0.4836	0.4875	0.0469	9.93
Max.	0.6440	0.6563	0.0624	9.76

8과 같으며, 수선하부의 선형특성 데이터만으로 학습한 결과 Equal Line에 대한 밀집도가 상대적으로 낮은 것으로 확인되었다.

Table 5와 같이 흡수별 전체적인 오차(MAE 및 MAPE)의 평균은 0.0547 및 9.85(%)인 것으로 계산되었고, 검증데이터의 흡수 범위에 대한 예측데이터의 중첩율은 약 72%인 것으로 확인되었다.

4.3 Hydrostatic Data 추론 결과

딥러닝으로 추론된 Hydrostatic Data의 수학적 모델에 대한 검증은 연속형 데이터 형태의 회귀모델 평가지표에 많이 활용되는 MAPE와 MAE 등을 사용하여, 딥러닝 모델의 학습범위(Range A) 및 각 선박의 최소 및 최대 운항흡수에 대한 딥러닝 추론범위(Range E)에 대하여 Table 6과 같이 계산하였다.

추론된 Hydrostatic Data에 따른 KMT Data의 각 흡수범위별 오차는 Table 7과 같이 계산되었고, 검증데이터에 대한 MAPE(%)는 Fig. 9와 같이 분포하는 것을 확인하였다.

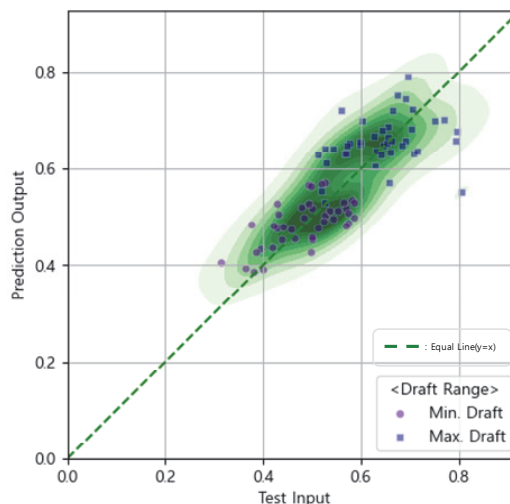


Fig. 8 Target data(draft range) learning result

Table 6. Deep Learning error for hydrostatic curve

Draft Range	Error Hydro. Data	Range A		Range E	
		MAPE (%)	MAE	MAPE (%)	MAE
Volume	Min	0.24	0.0006	0.14	0.0004
	Max	12.11	0.0413	10.97	0.0405
	Mean	3.37	0.0107	2.99	0.0108
KB	Min	0.29	0.0008	0.14	0.0004
	Max	8.46	0.0155	7.42	0.0159
	Mean	2.73	0.0060	2.19	0.0060
It	Min	0.55	0.0041	0.20	0.0016
	Max	10.62	0.0765	10.26	0.0762
	Mean	3.10	0.0198	2.23	0.0164
Total Mean		3.07	0.0122	2.47	0.0111

Table 7. Deep learning error for KMT curve

Draft Range	Error Hydro. Data	Range A		Range E	
		MAPE (%)	MAE	MAPE (%)	MAE
KMT	Min	0.59	0.0191	0.24	0.0057
	Max	5.90	0.2813	6.47	0.2361
	Mean	2.94	0.0943	2.31	0.0643

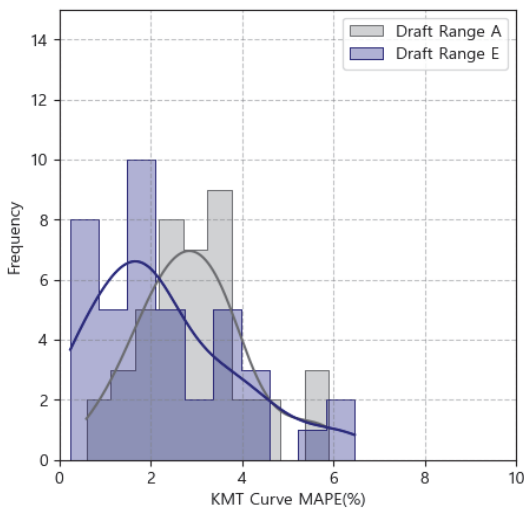


Fig. 9 Distribution of KMT curve MAPE(%)

4.4 운항상태별 GM 추정 계산

본 연구에서 활용된 학습데이터의 선박의 형깊이(D_m)에 따른 최대 및 최소 운항상태에서 선박의 연직방향 무게중심(KG)의 분포는 Fig. 10과 같이 조사되었고, 최소 및 최대 흘수에서 KG의 평균은 각각 D_m 의 1.136 및 1.161로 계산되었다. 본 연

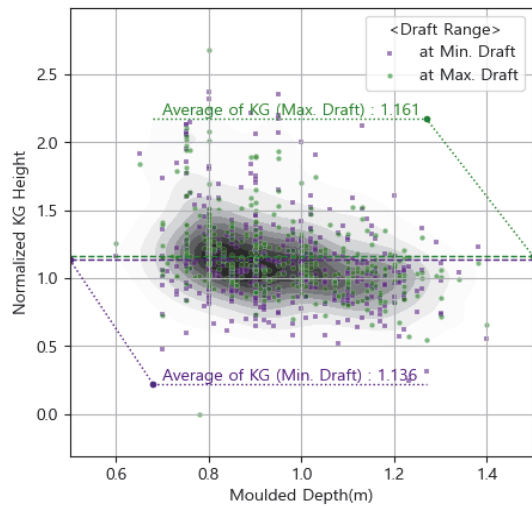


Fig. 10 Distribution of KG for loading condition

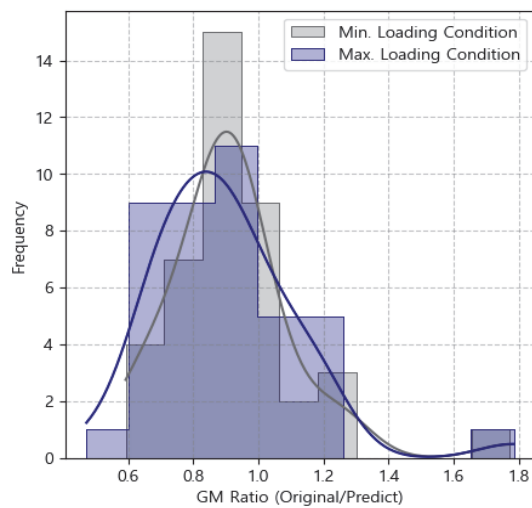


Fig. 11 Distribution of GM ratio

Table 8. Statistics of GM ratio

Statistics	Loading Draft	GM Ratio	
		Min. Draft	Max. Draft
Mean		0.9196	0.8971
Min.		0.5922	0.4716
Max.		1.7730	1.7847
Standard Deviation		0.2078	0.2245
Quartile	25%	0.8204	0.7420
	50%	0.8991	0.8719
	75%	0.9750	1.0044

구에서는 딥러닝으로 추론된 Hydrostatic Curve, 운항흘수 및 KG의 평균값 등을 적용하여, 검증데이터의 최소 및 최대 흘수구간(Range E)에 대한 GM 예측값을 계산하였고, Fig. 11과 같이 딥러닝 모델의 예측된 운항 흘수범위(Range E)에서 추론된 GM 값의 실제 GM에 대한 비율인 GM Ratio의 분포를 확인하였으며, 통계량은 Table 8과 같이 정리하였다.

5. 결론 및 후속 과제

본 연구에서는 Chine형 소형선박의 일반배치도에서 추출할 수 있는 선형특성데이터를 입력 변수로 설정하여, 초기복원성계산에 필요한 Hydrostatic Data와 선박별 운항흘수 범위 등을 인공지능 기법인 다층신경망 구조의 딥러닝 모델로 추론하였으며, 다음과 같은 결과를 확인할 수 있었다.

- 1) Form Parameter를 이용한 Hydrostatic Data의 수학적 모델 변환이 가능하고, 전체적인 오차(MAPE)는 평균 1.04%로 계산되었다.
- 2) 일반배치도에서 식별할 수 있는 선형특성데이터를 입력데이터로 설정한 딥러닝 모델 학습을 통하여 초기복원성 계산이 가능한 Hydrostatic Data의 추론이 가능하고, 전체

오차(MAPE)의 평균은 3.07%이며, 추론된 운항 흘수별 오차의 분포는 2.47%인 것으로 계산되었으며,

- 3) 본 연구에서 구현한 딥러닝 모델에 의하여 추론된 KMT(Transverse Metacenter Height) Curve는 2.94%의 오차(MAPE)가 전체 학습 범위내에서 발생하였으며, 개별 운항 범위내의 영역에서는 2.31%의 오차가 발생하였다.
- 4) 선박 운항 흘수별 초기 GM의 검증 데이터에 대한 추론된 예측데이터의 비율(%)의 평균은 최소흘수 상태에서 91.0%, 최대흘수에서 89.7%인 것으로 계산되었다.

이상과 같이 본 연구에서는 소형선박의 제한된 설계데이터(일반배치도)로부터 초기복원성 계산에 필요한 Hydrostatic Data와 초기 복원성계산이 딥러닝 추론으로 가능한 것을 확인하였다. 많은 실적선 데이터가 추가로 확보되어, Chine 형태 및 위치에 대한 유형별 지도학습이 가능하고, Hydrostatic Data 항목에 대한 후속 연구와 선박 운용형태에 대한 데이터 및 상부구조물 등의 학습 데이터의 보완이 이루어진다면, 국내 연안의 소형선박에 대한 복원성 계산 기초자료로서 활용가능성은 더욱 높아질 것으로 기대한다.

사 사

이 논문은 2023년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원과(P0023684, 2023년 산업혁신인재성장지원사업), 해양수산부 재원으로 해양수산과학기술진흥원의(20220210, AI 기반 스마트 어업관리시스템 개발) 지원을 받아 수행된 연구임.

참고문헌

- [1] 2022년 해양사고 통계, 중앙해양안전심판원.
- [2] G. Lee, A Study on the Estimation Method of EHP of Small Fishing Boats Having Chine Line and Optimization Technique of Hull Form Parameters Having Low Resistance, Journal of the Korean Society of Fisheries and Ocean Technology, pp.341-349, 1997.
- [3] J. Kim, A study for stability criteria of small fishing vessel, Thesis, Chosun University. 1999.
- [4] W. Park, S. Shin, S. Kim, Preliminary Hull Form Design Using Form Parameter Method and Neural Networks, J. Ocean Eng. Technol. 174-181. 1999.
- [5] D. K. Lee, A Study od Hull Form Surface Medeling Technique Using Approximate G^2 Surface Model, Thesis, Pusan National University. 1998.
- [6] Mariusz Doszyńa, Biasedness of forecast errors: an intermittent demand perspective, 26th International Conference on Knowledge-Based and Intelligent Information & Engineering Systems (KES 2022).

(접수: 2024.01.11. 수정: 2024.01.17. 게재확장: 2024.01.23.)