



공학석사 학위논문

인공신경망 및 고유변형모드에 의한 변환행렬기반 선체구조응답 예측방법개발

Development of conversion matrix based hull structural response prediction method by artificial neural network and distortion base modes

2023년 2월

서울대학교 대학원

조선해양공학과

양준혁

인공신경망 및 고유변형모드에 의한 변환행렬기반 선체구조응답 예측방법개발

지도교수 김 도 균

이 논문을 공학석사 학위논문으로 제출함 2023년 2월

> 서울대학교 대학원 조선해양공학과 양준혁

양준혁의 공학석사 학위논문을 인준함 2023년 2월

위 위	원장_	노 명 일	(인)
부위	원장 _	김 도 균	(인)
위	원_	남 보 우	(인)

초 록

최근 선체 구조 건전성을 추정하기 위한 방법을 개발하는 연구들이 수행되고 있다. 이는 설계 규정과 같은 선체 구조 건전성을 획득하기 위한 기존 방법들이 통계적 추정치에 근거하고 있어 불확실성을 지니기 때문이다. 따라서 실시간 계측 데이터를 활용하여 선체 구조 건전성을 확인하는 기술이 필요하다. 이를 실현하기 위해 실제 선박을 가상 공간에 투영한 디지털 트윈의 개념을 도입한 방법이 고안되었다. 이러한 방법은 수치 모델을 만들어 비교적 적은 개수의 계측 데이터로부터 선체 모든 곳의 구조 응답을 추정하는 것을 목표로 한다. 이 때 선체 구조 응답을 고유 모드 구조응답의 선형결합으로 가정함으로써 변환모델을 계산하는 연구들이 수행되어왔다.

본 논문은 선상 계측 데이터로부터 미계측위치의 구조 응답을 추정하는 변환모델을 다룬다. 이 때, 변환모델은 고유 모드 중첩을 가정한다. 선박의 적재 상태에 따라 변환모델이 추정한 구조응답의 정확도가 달라지는 한계를 개선하기 위하여 운동해석 결과로부터 구조해석 결과를 추정하는 인공신경망을 학습시켰다. 수치 해석 환경에서 기존의 변환모델과 본 연구가 제시한 변환모델로 추정한 구조응답을 비교함으로써 유효성을 검증하였다.

주요어 : 선체 구조 건전성, 고유 모드 중첩, 인공신경망, 디지털 트윈, 변환 모델

학 번 : 2021-28246

i

목	え
-	· · ·

	차
--	---

1.	서론		1
	1.1.	연구의 배경	.1
	1.2.	선행연구	.3
	1.3.	연구목표	.5
2.	연구 21	방법 수서도	7
	2.1. 2.2.	변화행렬 유도 과정	10
	2.3.	고유변형모드 선정 알고리즘	15
	2.4.	인공신경망의 구조	23
	2.5.	인공신경망의 학습	26
3.	적용	예시	34
	3.1.	입력값의 정의	34
	3.2.	검증과정의 수립	38
	3.3.	인공신경망의 구조 및 학습	11
	3.4.	변환행렬의 계산	12
	3.5.	구조응답 추정	19
4.	논의	5	56
5.	결론	5	59
참.	고 문	헌6	52
At	ostrac	ct6	54

표 목차

표	1. 적화상태에 따른 FPSO 모델의 주요 제원
표	2. LCS의 위치
표	3. 적화상태의 분류: CASE A 38
표	4. 적화상태의 분류: CASE B 38
표	5. 인공신경망으로 추정한 LC#2 가상 LBSG 응력전달함수의 상관
	계수43
표	6. 인공신경망으로 추정한 LC#2 핫스팟 응력전달함수의 상관계수44
표	7. CASE A CONV#1의 고유변형모드
표	8. CASE A CONV#4의 고유변형모드
표	9. CASE A PROP의 고유변형모드
표	10. 인공신경망으로 추정한 LC#3 가상 LBSG 응력전달함수의 상관
	계수
표	11. 인공신경망으로 추정한 LC#3 핫스팟 응력전달함수의 상관계수
표	12. CASE B CONV#2의 고유변형모드 48
표	13. CASE B CONV#4의 고유변형모드 48
표	14. CASE B PROP의 고유변형모드 49
표	15. 파 스펙트럼

그림 목차

그림	1. 파랑빈도자료(WAVE SCATTER DIAGRAM)의 예시	1
그림	2. 연구과정의 순서도	7
그림	3. 계측 구조응답(X)과 고유변형모드의 관계	11
그림	4. 미계측 구조응답(F)과 고유변형모드의 관계	13
그림	5.BIGOT 외(2015)의 고유변형 선택 알고리즘	17
그림	6. 고유변형모드의 예시	19
그림	7. 이대영(2022)의 고유변형모드 선택 알고리즘	22
그림	8. 인공신경망 구조의 예시	24
그림	9. TANH 함수	25
그림	10. 응력전달함수 추정을 위한 인공신경망의 구조	26
그림	11. 과적합(OVERFITTING)의 예시	27
그림	12. 학습과정에 따른 손실함수의 변화	28
그림	13. 인공신경망의 학습 알고리즘	32
그림	14.FPSO의 수치모델	34
그림	15. 가상 LBSG의 위치	36
그림	16. 핫스팟(HOTSPOT)의 요소(ELEMENT)	37
그림	17. 핫스팟(HOTSPOT)의 위치	37
그림	18. 변환모델의 검증과정	39
그림	19. 해석결과와 추정결과의 비교	50
그림	20. CASE A 핫스팟 응력전달함수 추정결과 비교(STEP 1)	51
그림	21. CASE A, SPECTRUM#1에 대한 추정결과 비교(STEP 2).	52

그림 22. CASE A, SPECTRUM #2에 대한 추정결과 비교(STEP 2) 53 그림 23. CASE B 핫스팟 응력전달함수 추정결과 비교(STEP 1) 54 그림 24. CASE B, SPECTRUM #1에 대한 추정결과 비교(STEP 2) 55 그림 25. CASE B, SPECTRUM #2에 대한 추정결과 비교(STEP 2) 55

1. 서론

1.1. 연구의 배경

선박을 건조할 때에는 전체 운용 기간 중 선체 구조 건전성을 유지할 수 있도록 다양한 과정을 거친다. 이 때, 설계하중 등을 결정할 때 통계 자료를 활용한다. 예를 들어, DNV CN 30.7을 따라 장기 피로해석을 수행하려면 파주파수, 파고와 같이 해상환경에 대한 정보가 필요한데, 이 때 파랑빈도자료(Wave scatter diagram)와 같은 통계 자료를 적용하여 장기 피로해석을 수행한다.

Tz(s)	3.5	4.5	5.5	6.5	7.5	8.5	9.5	10.5	11.5	12.5	13.5	14.5	15.5	16.5	17.5	18.5	Sum
Hs (m)																	
0.5	1.3	133.7	865.6	1 186.0	634.2	186.3	36.9	5.6	0.7	0.1	0	0	0	0	0	0	3 050
1.5	0	29.3	986.0	4 976.0	7 738.0	5 569.7	2 375.7	703.5	160.7	30.5	5.1	0.8	0.1	0	0	0	22 575
2.5	0	2.2	197.5	2 158.8	6 230.0	7 449.5	4 860.4	2 066.0	644.5	160.2	33.7	6.3	1.1	0.2	0	0	23 810
3.5	0	0.2	34.9	695.5	3 226.5	5 675.0	5 099.1	2 838.0	1 114.4	337.7	84.3	18.2	3.5	0.6	0.1	0	19 128
4.5	0	0	6.0	196.1	1 354.3	3 288.5	3 857.5	2 685.5	1 275.2	455.1	130.9	31.9	6.9	1.3	0.2	0	13 289
5.5	0	0	1.0	51.0	498.4	1 602.9	2 372.7	2 008.3	1 126.0	463.6	150.9	41.0	9.7	2.1	0.4	0.1	8 3 2 8
6.5	0	0	0.2	12.6	167.0	690.3	1 257.9	1 268.6	825.9	386.8	140.8	42.2	10.9	2.5	0.5	0.1	4 806
7.5	0	0	0	3.0	52.1	270.1	594.4	703.2	524.9	276.7	111.7	36.7	10.2	2.5	0.6	0.1	2 586
8.5	0	0	0	0.7	15.4	97.9	255.9	350.6	296.9	174.6	77.6	27.7	8.4	2.2	0.5	0.1	1 309
9.5	0	0	0	0.2	4.3	33.2	101.9	159.9	152.2	99.2	48.3	18.7	6.1	1.7	0.4	0.1	626
10.5	0	0	0	0	1.2	10.7	37.9	67.5	71.7	51.5	27.3	11.4	4.0	1.2	0.3	0.1	285
11.5	0	0	0	0	0.3	3.3	13.3	26.6	31.4	24.7	14.2	6.4	2.4	0.7	0.2	0.1	124
12.5	0	0	0	0	0.1	1.0	4.4	9.9	12.8	11.0	6.8	3.3	1.3	0.4	0.1	0	51
13.5	0	0	0	0	0	0.3	1.4	3.5	5.0	4.6	3.1	1.6	0.7	0.2	0.1	0	21
14.5	0	0	0	0	0	0.1	0.4	1.2	1.8	1.8	1.3	0.7	0.3	0.1	0	0	8
15.5	0	0	0	0	0	0	0.1	0.4	0.6	0.7	0.5	0.3	0.1	0.1	0	0	3
16.5	0	0	0	0	0	0	0	0.1	0.2	0.2	0.2	0.1	0.1	0	0	0	1
Sum	1	165	2 091	9 280	19 922	24 879	20 870	12 898	6 2 4 5	2 479	837	247	66	16	3	1	100 000

그림 1. 파랑빈도자료(Wave scatter diagram)의 예시

설계 단계에서 선체 구조 건전성에 대한 대비가 충분히 이뤄졌다고 해도 실제 운항 중 발생한 데이터와 설계 단계에 반영한 데이터 사이에 차이가 발생한다. Barhoumi와 Storhaug(2014)이 수행한 연구에 따르면, 선속과 풍속 등에 따라 선체에 가해지는 피로손상도가 달라진다. 이 때, 풍속 실 계측 데이터가 통계자료와 다르다는 것을 확인하였다.

설계 단계와 실제 운항 시 달라지는 요소는 이 외에도 선박의 적재 상태, 파고 등이 있으며, 이로 인해 실제 피로손상도가 달라지게 된다. 이렇듯 선체 구조 건전성을 획득하기 위한 기존의 방법들은 통계적 추정치에 근거하고 있기에 불확실성을 지닌다. 설계마진을 적용하는 방법 등을 적용하는 경우, 배수량 혹은 선박 제작 비용 측면에서 비효율적일 수 있다.

따라서, 설계 단계에서 발생하는 불확실성을 보완하기 위해 실제 선박의 계측 데이터로 선체 구조 건전성을 판별하는 연구들이 수행되어 왔다. 이러한 연구 중 가상공간에서 실제 해상구조물의 복제를 만드는 디지털 트윈(Digital twin)의 개념을 도입하여 실제 구조응답을 추정하는 연구들이 존재한다. 이러한 연구들은 제한된 개수의 계측데이터로 해상 구조물의 국부 혹은 전체 구조응답을 추정하는 것을 목표로 삼았다. Tygesen 외(2018)는 실제 해상 구조물을 복제한 유한요소 모델(Finite Element Model)과 실 계측 데이터를 바탕으로 실제 구조응답을 추정하는 연구를 수행하였다. 이 때, FE model이 실제 선박을 잘 복제할수록 추정한 구조응답의 정확도가 상승하였다.

디지털 트윈 개념을 도입한 일부 연구들은 계측 데이터를 활용하여 실제 구조응답을 정확하게 추정하는데 그치지 않고 이를 설계 단계 데이터와 결합하는 방법을 제시하였다. 제시된 방법들은 선박을 운용하는데 필요한 구조응답 등의 정보를 예측한다. 한 예시로 Meulen과 Hageman(2013)은 Nonparametric Bayesian analysis에

기반하여 설계단계의 피로손상도와 계측된 정보로 계산한 피로손상도를 통합하여 미래의 피로손상도를 예측하는 방법을 고안하였다. 예측된 정보는 선박의 검사 및 보수 작업을 수행할 때 활용될 수 있다.

선박에는 hatch coaming 와 같은 구조적으로 취약한 부위들이 존재한다. 이러한 주요 부재들의 구조응답을 가장 정확히 계측하는 방법은 모든 주요 부재들 위치에 센서를 부착하는 것이다. 하지만 이는 비용, 유지 및 보수 등의 측면에서 비효율적이기 때문에 일부의 계측 데이터로부터 주요 부재의 계측 데이터를 추정하는 방법에 대한 수요가 존재한다. 이러한 기술을 실현하기 위해 디지털 트윈 모델에서 계측 위치와 추정하고자 하는 부재의 위치에 가상의 센서를 지정하고, 디지털 트윈 모델에서 얻은 정보를 활용하여 주요 부재의 실 계측 구조응답을 추정하는 연구가 수행되어 왔다. 이러한 디지털 트윈 기반 선체구조응답 추정기법을 고안할 때 최소한의 계측 데이터로 추정한 구조응답의 정확도를 극대화하는 것에 주안점을 둔다.

1.2. 선행연구

실제 선박에서 구조응답을 추정하고자 하는 모든 위치에 센서를 설치하는 것은 여러 문제를 수반한다. 따라서, 제한된 가짓수의 정보로부터 미계측위치의 선체구조응답을 추정하는 연구가 꾸준히 수행되어 왔다. Moreira 와 Soares(2020) 은 인공신경망을 활용하여 선체 운동으로부터 수직 굽힘 모멘트와 전단력을 추정하는 모델을 제시하였다. Kobayashi, Jumonji, Murayama(2019)는 iFEM(inverse

Finite Element Method)을 이용하여 stiffened panel의 변형을 정확히 예측하는 연구를 수행하였다.

위와 같은 구조응답을 추정하는 방법에 대한 연구 중 일부는 고유모드 중첩 가정에 기반한 변환모델을 제시하였다. Baudin 외(2013)는 유한요소법으로 구한 고유진동모드를 활용하여 선체 위의 LBSG(Long base strain gauge)에서 계측한 구조응답으로부터 수직 굽힘 모멘트를 추정하는 변환모델을 제안하였다. Bigot, Derbanne, Baudin(2013)이 수행한 연구에서는 고유진동모드 외의 다른 종류의 고유모드를 바탕으로 변환행렬을 계산한 후, Hatch coaming 응력을 포함한 계측되지 않은 구조응답을 추정하였다. 이 중 정규파에서의 구조응답에서 고유모드를 선정하여 계산한 변환행렬로 추정한 결과가 가장 정확하였다. 고유진동모드와 달리 정규파에서의 구조응답은 고유치 문제가 존재하지 않는다. 따라서 정규파에서의 구조응답에서 고유모드를 선정하는 경우, 고유치 문제와는 다른 별도의 기준이 필요하다. 이를 해결하고자 Bigot 외(2015)는 정규파에서의 구조응답에서 고유변형모드(Distortion base mode)를 선정하는 알고리즘에 대한 연구를 수행하였다. 정규파에서의 구조응답에서 고유변형모드를 선정한 변환행렬은 고유진동모드를 고유모드로 선정한 변환행렬보다 정확한 추정결과를 제시하였다. 정규파에서의 구조응답에서 고유변형모드를 선정하는 경우 고유진동모드를 구할 때와 달리 첫번째 고유변형모드와 고유변형모드의 개수를 별도로 설정한다. 이대영(2022)은 Bigot(2015) 외가 제시한 알고리즘에 첫번째 고유변형모드와 고유변형모드의 개수를 최적화하는

과정을 추가하였다. 이후 변환행렬을 작성하여 주요 부재의 구조응답 등을 추정한 결과가 기존의 알고리즘으로 구한 변환행렬로 추정한 결과보다 개선된 것을 확인하였다. 변환행렬을 계산할 때 설정한 적화상태(Loading condition)가 실제 추정하고자 하는 구조응답에 해당하는 적화상태와 다른 경우, 정확도가 달라지는 한계를 가지고 있다. 이를 해결하고자 모든 적화상태에 대해 구조해석을 수행하는 것은 시간 측면에서 비효율적일 수 있다.

이러한 한계점을 개선하기 위하여 본 논문에서는 인공신경망을 활용하여 다양한 화물 적화상태에서의 구조해석 결과를 추정하였다. 이는 인공신경망을 활용하여 각종 구조물의 구조응답 혹은 피로손상도 등을 추정하는 연구가 꾸준히 수행되었기 때문이다. 김현진 외(2018)는 인공신경망을 활용하여 바람 터빈 지지 구조물의 구조해석 결과를 추정하는 연구를 수행하였다. 인공신경망으로 추정한 결과를 활용함으로써 수행해야 되는 시뮬레이션의 가짓수를 줄일 수 있는 가능성을 제시하였다. Chang, Lin, Chang(2018)은 고유진동수와 같은 모달 파라미터(modal parameter)을 입력하였을 때 구조물의 손상도를 추정하는 인공신경망을 제시하였다.

1.3. 연구목표

본 논문에서는 구조해석 결과가 없는 적화상태의 계측 신호로부터 추정하고자 하는 위치의 구조응답을 추정하는 변환모델을 제시하는 것을 목표로 한다. 2장에서는 변환모델 작성과 검증과정에 관한 내용을 담고 있다. 정규파에서의 구조응답에서 고유변형모드를 선정하며, 선정하는 과정을 설명한다. 본 논문에서는 다양한 화물 적화상태에서의 구조해석 결과 추정을 위한 인공신경망을 제시하였으며, 인공신경망이 학습되는 과정 또한 2장에 포함되어 있다.

3장에서는 본 논문에서 제시한 변환모델이 기존의 방법보다 정확성을 개선하였는지 여부를 확인한다. 검증을 위한 가상환경을 구축하였는지를 설명한다. 이후 FE 모델에서 가상 센서 위치와 구조응답을 추정하고자 하는 위치를 선정한다. 해석을 통하여 정규파에서의 구조응답을 계산했고, 이로부터 본 연구에서 제시한 방법과 기존 방법으로 계산한 2종류의 변환행렬을 계산했다. 가상 센서 데이터를 계산하고, 변환행렬에 입력함으로써 목표 위치의 구조응답을 추정하였다. 변환행렬이 2종류이기 때문에 추정한 구조응답도 2종류이다. 본 연구에서 제시한 변환행렬로 추정한 구조응답이 해석으로 구한 구조응답과 더 가까운지를 확인함으로써 검증과정을 수행하였다.

2. 연구 방법

2.1. 순서도

수치해석에 해당하는 적화상태(설계 적화상태)와 추정하고자 하는 구조응답에 해당하는 적화상태(목표 적화상태)가 다른 경우, 본 논문에서 제시한 변환행렬을 작성하는 방법과 기존의 방법의 차이를 그림 2 와 같이 순서도로 제시하였다.



그림 2. 연구과정의 순서도

그림 2 와 같이 Bigot(2015)와 이대영(2022)이 제시한 방법과 본 논문이 제시하는 방법의 가장 큰 차이는 응력전달함수(Stress transfer function) 추정을 위한 인공신경망이다. '입력값의 정의'단계에서는 변환행렬을 작성하기 위한 선박의 주요 제원을 지정한다. 가상 센서를 부착되는 위치와 구조응답을 추정할 위치를 설정한다. 검증과정을 수행하기 위하여 여러가지 적화상태에 대한 수치해석이 필요한데, 이 적화상태들을 이 단계에서 정의한다.

'검증 과정의 수립'단계에서는 변환행렬을 작성하는 방법을 분류하고, 각 방법의 결과물을 어떻게 비교할지를 정의한다. '입력값의 정의'단계에서 정한 적화상태들 중에서 수치해석을 수행하는 적화상태인 설계 적화상태와 추정할 구조응답에 해당하는 목표 적화상태를 분류한다.

'수치해석' 단계에서는 전 단계에서 분류한 설계 적화상태에 입각하여 수행할 수치해석을 정의한다. 본 논문에서는 정규파에서의 구조응답에서 고유변형모드를 선정한다. 따라서 구조해석 뿐만 아니라 운동해석 역시 수행한다. 각 해석의 결과물인 응력과 선체 거더 하중의 전달함수(Transfer function)는 기존의 방법 또는 본 논문이 제시하는 방법에 따라 용도가 나뉜다. 기존의 방법으로 변환행렬을 작성하는 경우, 2가지의 전달함수는 그대로 고유변형모드 선정 알고리즘에 입력된다. 본 논문에서 제시하는 방법에 따라 변환행렬을 작성할 때는 인공신경망의 학습에 활용된다.

'인공신경망 학습'단계에서는 인공신경망의 구조 및 인공신경망의 학습 시 활용하는 알고리즘을 선정한다. 퍼셉트론(Perceptron)의 개수, 은닉층(Hidden layer)의 개수, 활성화 함수(Activation function)와 같이 주요 변수를 지정하여 인공신경망 구조를 확정한다. 인공신경망을

'수치해석'단계의 결과물로 인공신경망을 학습시킨다. 따라서, 이 단계의 목적은 운동해석 결과로부터 구조해석 결과를 추정하는 인공신경망을 만드는 것이다.

'운동해석' 단계에서는 목표 적화상태에 대하여 운동해석을 수행한 후, 결과를 인공신경망에 대입함으로써 목표 적화상태에 대한 구조해석 결과를 추정한다. 인공신경망으로 추정한 구조해석 결과와 목표 적화상태에 대한 운동해석 결과를 고유변형모드 선정 알고리즘에 입력함으로써 변환행렬 [Aproposed] 을 구할 수 있다. 기존의 방법은 설계 적화상태의 수치해석 결과로부터 변환행렬 [Aconventional] 을 계산한다. 즉, 두 방법의 차이점은 고유변형모드 선정 알고리즘에 입력되는 값의 차이다.

'목표 적화상태의 응력 추정'에서는 [Aproposed], [Aconventional] 2종류의 변환행렬로 추정하고자 하는 구조응답을 정의한다. 실 계측 데이터로 검증하는 것은 noise 등의 문제로 실현하는데 어려움이 있다. 따라서 목표 적화상태에 대하여 수치해석을 수행한 후 가상공간에서 계측 데이터와 추정대상의 구조응답을 계산한다. 이후 각 변환행렬로 추정대상의 구조응답을 추정한다. '적용사례를 통한 검증'단계에서는 앞서 설명한 2종류의 변환행렬로 구한 추정값을 수치해석으로 구한 데이터와 대조한다. 본 연구에서 제시한 변환행렬 [Aproposed] 로 추정한 구조응답이 수치해석으로 구한 추정대상의 데이터와 일치하는지 여부를 확인함으로써 검증과정을 수행한다.

2.2. 변환행렬 유도 과정

본 논문에서는 계측된 구조응답으로부터 미계측 위치의 구조응답을 추정하는 변환행렬을 제시한다. 즉, 두 변수 사이에 선형관계가 존재한다는 것을 가정한다. 이 때, 계측된 구조응답 <u>X</u>와 미계측 위치의 구조응답 F은 식 (1), 식 (2) 와 같다.

$$\underline{X} = \begin{bmatrix} X_1, X_2, \dots, X_{N_M} \end{bmatrix}^T \tag{1}$$

$$\underline{F} = \begin{bmatrix} F_1, F_2, \dots, F_{N_T} \end{bmatrix}^T \tag{2}$$

N_M 는 계측된 구조응답의 개수이며, 추정하고자 하는 구조응답의 개수는 N_T 이다. 계측된 구조응답과 미계측 위치의 구조응답 사이의 관계를 밝히기 위하여 본 논문에서는 고유모드 중첩을 가정하였다. 즉,
 본 논문에서는 선체의 구조응답은 고유변형모드 구조응답을 선형결함한 것으로 가정하였다. 계측된 구조응답 <u>X</u>을 고유변형모드 구조응답의 선형결합으로 나타낸 결과를 그림 3 으로 표현하였다.



그림 3. 계측 구조응답(<u>X</u>)과 고유변형모드의 관계 p번째 고유변형모드에서의 계측 구조응답 m_p 은 식 (3) 과 같다.

$$\underline{m_p} = \left[\left(m_p \right)_1, \left(m_p \right)_2, \dots, \left(m_p \right)_{N_M} \right]^T \quad (1 \le p \le P)$$
(3)

고유변형모드(Distortion base mode, DBM)의 개수가 P 일 때, 식 (4) 와 같이 계측된 구조응답 <u>X</u>를 m_p 의 선형결합으로 가정할 수 있다.

$$\underline{X} \approx \xi_1 * \underline{m_1} + \xi_2 * \underline{m_2} +, \dots, + \xi_P * \underline{m_P}$$
(4)

선형계수 $\xi_1, ..., \xi_p$ 를 식 (5) 와 같이 벡터로 정의하였을 때, 식 (6) 과 같이 계측된 구조응답 <u>X</u>를 행렬 <u>M</u>에 대한 식으로 나타낼 수 있다.

$$\underline{\xi} = [\xi_1, \xi_2, \dots, \xi_P]^T \tag{5}$$

$$\underline{X} \approx \begin{bmatrix} (m_1)_1 & (m_2)_1 & \cdots & (m_P)_1 \\ (m_1)_2 & (m_2)_2 & \cdots & (m_P)_2 \\ \vdots & \vdots & \ddots & \vdots \\ (m_1)_{N_M} & (m_2)_{N_M} & \cdots & (m_P)_{N_M} \end{bmatrix} \cdot \begin{bmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \vdots \\ \xi_P \end{bmatrix} = \underline{\underline{M}} \cdot \underline{\xi}$$
(6)

식 (6) 을 통하여 알 수 있는 것은 고유변형모드의 구조응답에 관한 행렬 <u>M</u>과 그 선형계수의 벡터 <u>ξ</u>을 구한다면, 계측 위치의 구조응답 <u>X</u>를 계산할 수 있다는 것이다. <u>M</u>의 (*i*,*j*) 성분은 'j번째 고유변형모드에서의 계측 구조응답 <u>m</u>_j의 i번째 성분'을 의미하며, 식 (7) 로 나타낼 수 있다.

$$\left(\underline{\underline{M}}\right)_{ij} = \left(m_j\right)_i \tag{7}$$

고유변형모드는 미계측 위치의 구조응답 <u>F</u>에도 동일하게 적용된다. 이를 고려하여 <u>F</u>를 고유변형모드의 구조응답에 대한 식으로 나타내는 과정을 그림 4 로 나타냈다.



그림 4. 미계측 구조응답(<u>F</u>)과 고유변형모드의 관계 p번째 고유변형모드에서의 미계측 구조응답 b_p은 식 (8) 과 같다.

$$\underline{b_p} = \left[\left(b_p \right)_1, \left(b_p \right)_2, \dots, \left(b_p \right)_{N_M} \right]^T \quad (1 \le p \le P)$$
(8)

계측된 구조응답 <u>X</u>와 추정하고자 하는 미계측 위치의 구조응답 <u>F</u> 모두 같은 고유변형모드를 공유한다. 따라서 고유변형모드의 개수는 P로 동일하며, 고유변형모드가 동일하기에 선형계수 ξ₁,...,ξ_P 도 동일하다. 이를 고려하여 식 (9) 와 같이 <u>F</u>를 <u>bp</u>의 선형결합으로 가정할 수 있다.

$$\underline{F} \approx \xi_1 * \underline{b_1} + \xi_2 * \underline{b_2} +, \dots, + \xi_P * \underline{b_P}$$
(9)

식 5 를 활용하여 미계측 구조응답 <u>F</u>를 행렬 <u>B</u>에 대한 식으로 나타낼 수 있다.

$$\underline{F} \approx \begin{bmatrix} (b_1)_1 & (b_2)_1 & \cdots & (b_P)_1 \\ (b_1)_2 & (b_2)_2 & \cdots & (b_P)_2 \\ \vdots & \vdots & \ddots & \vdots \\ (b_1)_{N_T} & (b_2)_{N_T} & \cdots & (b_P)_{N_T} \end{bmatrix} \cdot \begin{bmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \vdots \\ \xi_P \end{bmatrix} = \underline{\underline{B}} \cdot \underline{\xi}$$
(10)

행렬 <u>B</u>는 고유변형모드에서의 미계측 구조응답 <u>bp</u>를 열벡터로 가지는 행렬이며, 식 (11) 과 같이 정의할 수 있다.

$$\left(\underline{\underline{B}}\right)_{ij} = \left(b_j\right)_i \tag{11}$$

식 (6), 식 (10) 을 통해 고유변형모드에서의 구조해석 결과와 <u>₹</u>을 알고 있다면, 계측위치와 미계측위치의 구조응답을 계산할 수 있다는 것을 알 수 있다. 여기서 선형계수의 벡터 <u>₹</u>를 두가지 구조응답 <u>F,X</u> 모두 공유한다는 점을 이용하여, 고유모드의 구조응답에 대한 행렬 <u>B,M</u>으로부터 변환행렬을 계산할 수 있으며, 그 과정은 다음과 같다.

고유변형모드의 계측 구조응답에 대한 행렬 <u>M</u>의 크기는 (N_M×P)이다. 정방행렬이 아닌 경우, 역행렬을 구할 수 없다. 이러한 경우, 무어-펜로즈 유사역행렬(Moore-Penrose inverse)의 개념을 이용하여 식 (13) 와 같이 <u>ξ</u>를 <u>X</u>와 <u>M</u>에 대한 식으로 정리할 수 있다.

$$\underline{\underline{M}}^{T} \cdot \underline{X} = \underline{\underline{M}}^{T} \cdot \underline{\underline{M}} \cdot \underline{\underline{\xi}}$$
(12)

$$\underline{\xi} = \left(\underline{\underline{M}}^{T} \cdot \underline{\underline{M}}\right)^{-1} \cdot \underline{\underline{M}}^{T} \cdot \underline{X}$$
(13)

여기서 (<u>M</u>^T·<u>M</u>)⁻¹·<u>M</u>^T가 무어-펜로즈 유사역행렬이다. 식 (13) 을 식 (10) 에 대입하면 식 (15) 와 같이 계측 위치의 구조응답 <u>X</u>을 추정하고자 하는 미계측 구조응답 <u>F</u>로 변환하는 변환행렬 <u>A</u>를 구할 수 있다.

$$\underline{F} = \underline{\underline{B}} \cdot \left(\underline{\underline{M}}^{T} \cdot \underline{\underline{M}}\right)^{-1} \cdot \underline{\underline{M}}^{T} \cdot \underline{X} = \underline{\underline{A}} \cdot \underline{X}$$
(14)

$$\underline{\underline{A}} = \underline{\underline{B}} \cdot \left(\underline{\underline{M}}^{T} \cdot \underline{\underline{M}}\right)^{-1} \cdot \underline{\underline{M}}^{T}$$
(15)

식 (15) 에 제시된 바와 같이 변환행렬 <u>A</u>는 <u>B,M</u>으로부터 유도할 수 있다. 즉, 고유변형모드에 대한 구조응답만 구해도 변환행렬을 작성할 수 있다. 이로 인해 단순한 선형 근사 등의 방법보다 연산시간을 단축할 수 있다는 장점을 가진다. 다음 절에서는 고유변형모드를 선정하는 알고리즘에 대한 내용을 다룬다.

2.3. 고유변형모드 선정 알고리즘

본 논문에서는 정규파에서의 구조응답으로부터 고유변형모드를 선정한다. 고유진동모드와 달리 고유변형모드는 고유치 문제가 존재하지 않기 때문에, 모드를 선정하는 별도의 과정이 필요하다 이에 대해 연구로 Bigot 외(2015)가 연구를 수행한 바 있으며, 이대영(2022)는 Bigot 외(2015)의 고유변형모드 선택 알고리즘에 첫번째 고유변형모드 및 고유변형모드의 개수를 최적화하는 과정을 추가하였다. 본 논문에서는 이대영(2022)의 연구에서 제시한 고유변형모드 선택 알고리즘에 따라 고유변형모드를 선정하였다.

고유모드 선택 알고리즘에 대한 설명에 앞서 데이터 전 처리 과정을 수행하였다. 고유변형모드는 수치해석 결과로부터 선택된다. 따라서 충분한 개수의 주파수(Frequency), 회두각(Heading angle)에 대하여

운동해석 및 구조해석을 수행한다. 그 결과로써 각각 선체 거더 하중 전달함수(Hull girder load transfer function)과 응력 전달함수(Stress transfer function)을 구할 수 있다. 전달함수는 선박에 단위파와 조우하였을 때, 구조응답에서 cos 함수의 계수인 real part와 sin 함수의 계수인 imaginary part로 나눌 수 있다. 선박의 수치모델이 동일하다면, 전달함수는 주파수 ω, 회두각 β 에 대한 함수이다. 미계측 위치의 구조응답에 대한 전달함수를 구했을 때, real part <u>R</u>과 imaginary part *I*는 식 (16) 과 식 (17) 과 같다.

$$\underline{R}(\omega,\beta) = \left[R_1, \dots R_{N_T}\right]^{\mathrm{T}}$$
(16)

$$\underline{I}(\omega,\beta) = \begin{bmatrix} I_1, \dots I_{N_T} \end{bmatrix}^{\mathrm{T}}$$
(17)

전달함수 <u>R</u>(ω,β), <u>I</u>(ω,β)에 단위파 위상(unit wave phase) φ를 추가하면 정규파에서의 미계측 구조응답 <u>F</u>는 식 (18) 으로 정의할 수 있다.

$$\underline{F}(\omega,\beta,\phi) = \underline{R}(\omega,\beta) * \cos(\phi) + \underline{I}(\omega,\beta) * \sin(\phi)$$
(18)

즉, <u>F</u>는 주파수 ω , 회두각 β , 단위파 위상 ϕ 에 대한 함수라고 할 수 있으며, 이 때 (ω, β, ϕ) 의 조합을 wave load case 라고 한다. 수치해석 단계에서 설정한 주파수와 회두각의 개수가 각각 N_{ω} , N_{β} 이고, 단위파 위상의 개수를 N_{ϕ} 로 정의했다면, wave load case의 개수는 $N_{WLC} = (N_{\omega} * N_{\beta} * N_{\phi})$ 이다. i번째 wave load case를 $(\omega, \beta, \phi)_i$ 라고 할 때, 이에 해당하는 정규파에서의 구조응답은 <u>F</u> $(\omega, \beta, \phi)_i$ 이다.

Bigot 외(2015)가 제시한 고유모드 선정 과정은 그림 5 과 같다.



그림 5. Bigot 외(2015)의 고유변형 선택 알고리즘

고유치 문제를 풀어 고유모드를 선정한 경우, 고유모드 간 직교성이 보장된다. 이에 반해 정규파에서의 구조응답은 고유치 문제가 존재하지 않기 때문에, 고유변형모드 간에는 완벽한 직교성을 보장할 수 없다. 따라서 식 (20) 와 같이 상관계수를 정의한 후 서로 간의 상관계수가 낮도록 고유변형모드를 선정하였다.

$$\underline{f}(\omega,\beta,\phi)_i = \underline{S} * \underline{F}(\omega,\beta,\phi)_i \tag{19}$$

$$r(i|j) = \underline{f}(\omega,\beta,\phi)_i * \underline{f}(\omega,\beta,\phi)_j$$
(20)

즉, 임의의 *i,j* 번째 wave load case에 대하여 내적했을 때 0에 가깝도록 고유변형모드를 선정한다. 이 때, <u>S</u>은 크기가 전체적으로 높은 특정 성분으로만 고유변형모드가 선정되는 것을 방지하기 위한 행렬이며, 식 (21) 과 같이 정의된다.

$$S_{ij} = \delta_{ij} * \left[\max_{i \in [1, N_c]} \{ \underline{F}(\omega, \beta, \phi)_i \}_j \right]$$
(21)

즉, 주대각성분 외의 성분은 0이며, j번째 대각성분에는 모든 wave load case에 대한 <u>F</u>(ω,β,φ)_i의 j번째 성분 중에서 최댓값이 들어간다.

'Selection of the first mode' 단계에서는 첫번째 고유변형모드를 선택한다. Bigot 외(2015)가 제시한 고유변형모드 선택 알고리즘에서는 still water 상태의 변형상태와 가장 유사한 wave load case인 최대 수직 굽힘 모멘트(Vertical bending moment)가 발생하는 wave load case를 첫번째 모드로 선택한다.

'Calculation of N_c' 에서는 다음 모드를 고를 wave load case의 집합을 정한다. 식 (20) 에 같은 wave load case를 대입함으로써 <u>f</u>(ω,β,φ)_i 의 크기를 구할 수 있는데, 이를 자기상관계수라고 한다. 이 자기 상관계수가 (첫번째 모드의 자기상관계수)*0.8 보다 큰 wave load case들을 선별하는데, 그 개수를 변수 N_c 로 정의한다. 이 과정을 수행하는 이유는 변형의 유형은 비슷하나 그 정도나 크기가 작다는 이유만으로 고유변형모드로 선정되는 것을 방지하기 위함이다.



그림 6. 고유변형모드의 예시

고유치 문제를 통하여 구하는 고유진동모드는 그 크기와 관계없이 그림 6 과 같이 변형의 유형도 다르고 직교성을 가진다. 그러나 직교성이 항상 보장되는 것이 아닌 고유변형모드는 변형의 크기가 작은 wave load case끼리는 구조응답의 크기가 작기만 해도 상관계수가 낮은 경우가 발생할 수 있다. 이 때, 자기상관계수로 조건을 건다면 구조응답의 크기가 작은 wave load case가 제외된다. 이로 인해 크기가 크더라도 상관계수가 작은 wave load case들끼리 고유변형모드로 선정된다.

자기상관계수 조건을 만족한 N_c개의 wave load case와 미리 선정된 p개의 고유변형모드에 대한 상관계수 r(i|j)을 계산한다. 알고리즘에서는 먼저 a번째 wave load case를 고정하고 p개의 상관계수를 계산한다. 각 상관계수는 a번째 wave load case가 p개의 고유변형모드와 얼마나 직교성에 가까운지를 나타낸다. 새로 선택되는 고유변형모드는 이미 선정된 모든 고유변형모드에 대해 직교에 가까운 성질을 지녀야한다.

따라서 p개의 상관계수 중 가장 큰 값인 R_a 가 새 고유변형모드를 선택하는 기준이 된다. a는 자기상관계수 조건을 만족하는 wave load case에 대한 번호이기 때문에 R_a 는 총 N_c 만큼 존재한다.

'(ω,β,φ)_a of mininum R_a = new mode' 단계에서는 N_c 개의 R_a 중 가장 낮은 값을 가지는 wave load case (ω,β,φ)_a가 새 고유변형모드가 된다. 이미 선정된 고유변형모드의 개수가 p에 1을 추가하고, N_c 개의 원소를 가지는 집합에서 새 고유변형모드가 선정되었기 때문에 N_c에서 1을 뺀다. 일련의 과정을 미리 설정한 P개의 고유변형모드를 선정할 때까지 반복하는 것이 Bigot 외(2015)가 제시한 고유변형모드 선택 알고리즘이다.

선박 모델이 동일하다면 계측된 구조응답 <u>X</u>도 앞의 과정으로 선택된 P개의 고유변형모드(ω, β, ϕ)₁, $(\omega, \beta, \phi)_2, \cdots$, $(\omega, \beta, \phi)_P$ 를 공유한다. 이를 고려하여 ($N_T \times P$) 행렬 <u>B</u>와 ($N_M \times P$) 행렬 <u>M</u>은 식 (22), 식 23 과 같이 정리할 수 있다.

$$B_{ij} = \left(\underline{F}(\omega, \beta, \phi)_j\right)_i \tag{22}$$

$$M_{ij} = \left(\underline{X}(\omega, \beta, \phi)_{j}\right)_{i} \tag{23}$$

이대영(2022)은 고유변형모드 선택 알고리즘에 고유변형모드의 개수와 첫번째 고유변형모드를 최적화하는 과정을 추가하였다. Bigot 외(2015)가 제시한 고유변형모드 선택 알고리즘은 수직 굽힘 모멘트가 최대인 wave load case를 첫번째 고유변형모드로 선택한다. 새로운 고유변형모드는 이미 선택된 모든 고유변형모드와의 상관계수를 고려하여 선택하기 때문에, 첫번째 고유변형모드가 변하면 나머지 고유변형모드도 변화한다. 이는 곧 고유변형모드에 기반한 변환행렬의 값이 변화하는 것을 의미하며, 정확도 역시 변화하는 것을 의미한다.

고유치 문제가 존재하는 고유진동모드와 달리, 고유변형모드는 개수를 직접 지정해야 한다. 고유변형모드의 개수 역시 변환행렬의 정확도에 영향을 끼친다. 따라서 첫번째 고유변형모드와 고유변형모드의 개수를 변화시키면서 추정된 구조응답의 정확도를 비교함으로써 최적화를 수행할 수 있다. 이 때 변환행렬로 추정된 i번째 wave load case의 구조응답 <u>F'(ω,β,φ)</u>_i의 정확도는 식 (24) 와 같이 수치해석을 통해 구한 구조응답 <u>F(ω,β,φ)</u>_i 와 RMSE(Root mean squared error)을 계산하여 확인한다.

$$(RMSE) = \frac{1}{N_{WLC}} \sum_{i=1}^{N_{WLC}} \left(\underline{F}(\omega, \beta, \phi)_i - \underline{F'}(\omega, \beta, \phi)_i \right)^2$$
(24)

위의 내용을 알고리즘 순서도로 정리하면 그림 7 과 같다. 첫번째 고유변형모드와 고유변형모드의 개수를 최적화하는 과정을 제외하면 Bigot 외(2015)가 제시한 알고리즘과 동일하다. 따라서 동일한 과정을 'Mode selection algorithm' 으로 표시하였다.



그림 7. 이대영(2022)의 고유변형모드 선택 알고리즘

이대영(2022)이 제시한 그림 7 의 알고리즘에서는 고유변형모드의 개수가 [P₁,P₂,...,P_M]와 같이 총 개수가 M개인 범주로 주어진다. 이 때, 계측된 구조응답의 개수 N_M의 절반에 가까운 값으로 제시하는 것이 예측 결과가 좋다는 것을 확인하였다.

'Calculation of N₁'에서는 첫번째 고유변형모드가 될 wave load case의 집합을 만드는 과정이다. 충분한 크기의 구조응답을 가지는 wave load case를 선별하기 위하여 자기상관계수를 활용한다. 전체 wave load case 중 자기상관계수가 가장 높은 값의 *C*_{f1} 배보다 큰 경우에만 첫번째 고유변형모드가 될 수 있으며, 이를 식으로 나타내면 식 (25) 와 같다. *RS*₁는 첫번째 고유변형모드가 될 수 있는 wave load case의 집합이며, 그 크기는 *N*₁이다.

$$RS_{1} = \left\{ \underline{F}(\omega, \beta, \phi)_{i} \middle| r(i|i) \ge C_{f1} * \max_{j \in [1, N_{WLC}]} r(j|j) \right\}$$
(25)

첫번째 고유변형모드를 선택하는 방법이 Bigot(2015)가 제시한 알고리즘과 다르기 때문에, 이후 고유변형모드를 선택할 집합을 RS₂로 정의하고, 기준을 식 (26) 으로 제시하였다.

$$RS_2(i) = \left\{ \underline{F}(\omega, \beta, \phi)_k \middle| r(k|k) \ge C_{f2} * r(i|i) \right\}$$
(26)

이 때, $\underline{F}(\omega,\beta,\phi)_i$ 는 RS_1 에 포함된 원소이며, 따라서 위의 식은 첫번째 고유변형모드의 wave load case $(\omega,\beta,\phi)_i$ 에 따라 RS_2 가 달라진다는 것을 의미한다.

2.4. 인공신경망의 구조

운동해석 및 구조해석 결과로부터 고유변형모드를 선정하고 변환행렬을 계산하는 방법을 확인하였다. 선박의 수치모델은 적화상태에 따라 달라지며, 이 때 고유변형모드 역시 변화한다. 이에 대응하기 위하여 모든 적화상태에 대하여 수치해석을 수행하는 경우 지나치게 많은 시간이 소요될 우려가 있다. 따라서 본 논문에서는 상대적으로 시간이 적게 걸리는 운동해석 결과로부터 구조해석 결과를 추정하는

인공신경망을 학습시켰다. 학습과정에 앞서 기초적인 인공신경망의 예시를 그림 8 로 제시하였다.



그림 8. 인공신경망 구조의 예시

인공신경망은 입력층 (Input layer), 은닉층 (Hidden layer), 출력층 (Output layer)으로 이루어져 있다. 이 중 은닉층은 여러 층으로 존재할 수 있으며, 그림 8 은 은닉층이 2층인 인공신경망의 예시이다. 3가지의 층(Layer)은 모두 노드(node)로 구성되어 있으며, 노드의 구성 및 배치를 결정하는 것이 인공신경망의 구조를 정하는 것이라고 할 수 있다. 각 노드는 이전 층의 모든 노드와 연결되어 있다. 각 노드를 연결하기 위하여 가중치(weight)와 편향(bias)이 적용된다. 예를 들어, 그림 8 에서 첫번째 은닉층 i번째 노드에 입력되는 값 v_a 는 식 (27) 과 같다.

$$v_i = b_i + \sum_{j=1}^{N} (w_{ij} * x_j)$$
(27)

N은 그림 8 에서 제시한 입력값의 개수이며, x_j는 입력값이다. 은닉층 i번째 노드의 결과값은 식 (28) 과 같다.

$$h_i = f(v_i) \tag{28}$$

f 는 활성화함수(Activation function)이며, 인공신경망의 구조를 결정할 때 정한다. 활성화함수에는 Sigmoid, tanh 등이 존재하지만, 본 논문에서는 TANH 함수를 사용하였으며, 식 (29), 그림 9 와 같다.



$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$
(29)

그림 9. TANH 함수

만약 활성화함수가 선형함수(f(x) = ax + b)만 존재한다면 선형 근사와 같은 결과밖에 얻을 수 없다. TANH 함수는 인공신경망을 활용하는 많은 연구에서 활성화함수로 선택된다.

위의 내용을 바탕으로 본 논문에서는 그림 9 와 같이 운동해석으로 구한 선체 거더 하중 전달함수를 입력했을 때, x축 응력 전달함수를 추정하도록 인공신경망의 구조를 정하였다. 은닉층의 층수와 노드의

개수는 선박 모델에 따라 달라진다.



그림 10. 응력전달함수 추정을 위한 인공신경망의 구조

 x방향 응력을 추정하는 것이 목적이기에 출력층의 노드는 1개이다.

 입력층에 배치된 변수들은 모두 운동해석 결과로부터 얻을 수 있는

 값이다. FE 모델에서 응력을 구한 절점(Node) 혹은 요소(Element)의

 x좌표와 운동해석을 위해 설정한 Load cross section의 x좌표가

 동일하게 설정하였다. 6번째 입력값인 압력은 Panel 모델 상의 위치가

 응력을 구한 절점 또는 요소의 위치가 최대한 가깝도록 하였다.

2.5. 인공신경망의 학습

인공신경망을 학습시키는 것은 모든 노드의 가중치와 편향을 손실함수(Loss function)에 대하여 최적화하는 과정이라고 할 수 있다. 대표적인 손실함수는 식 (30) 과 같은 MSE(Mean Squared Error)을 꼽을 수 있다.

$$(MSE) = \sum (y_i - y'_i)^2$$
(30)

y_i는 인공신경망의 학습 데이터 중 출력값이며, y'_i은 인공신경망에 학습 데이터 중 y_i에 대응하는 입력값 x_i을 대입함으로써 얻을 수 있는 추정값이다. 즉, MSE는 인공신경망으로 추정한 값과 학습 데이터 사이의 오차를 나타내는 함수라고 할 수 있다. 별도의 과정없이 MSE를 최적화하는 방향으로 학습을 수행하는 경우, 과적합(Overfitting) 문제가 발생할 수 있다. 인공신경망을 활용하는 목적은, 학습 데이터를 바탕으로 입력 변수와 출력 변수 간의 상관관계를 이끌어내는 것이다. 하지만, 별도의 과정을 거치지 않는다면 그림 11 과 같이 학습 데이터에 대해서만 오차를 줄이는 방향으로 인공신경망을 학습하게 된다. 이러한 과적합을 방지하기 위한 수단으로는 데이터의 분할, 정규화, 학습 조기종료 등의 수단이 있다.



그림 11. 과적합(Overfitting)의 예시

학습 데이터셋(Train dataset) 중 일부를 검증 데이터(Validation dataset), 테스트 데이터셋(Test dataset)으로 분할함으로써 과적합을 방지할 수 있다. 이중 테스트 데이터셋은 학습이 완료된 인공신경망의 손실함수를 계산함으로써 인공신경망의 추정결과가 정확한지의 지표로 활용된다. 검증데이터셋은 학습 과정에 관여함으로써 과적합 방지에 기여한다.



그림 12. 학습과정에 따른 손실함수의 변화

그림 12 는 반복횟수(n)에 대한 특정 인공신경망의 손실함수(L)의 에시이다. 반복횟수가 커질수록 학습데이터에 대한 손실함수가 작아지는 것을 확인할 수 있다. 만약 데이터셋을 분할하지 않는다면, 손실함수가 증가하지 않기 때문에 학습과정이 계속된다. 하지만 데이터셋 일부를 검증 데이터셋으로 할당한다면, n=15과 같이 학습 데이터셋의 손실함수는 감소하지만, 검증 데이터셋의 손실함수는 증가하는 지점이 발생한다. 이 때 인공신경망의 학습을 중단함으로써 그림 11 과 같은
과적합을 방지할 수 있다.

본 연구에서 적용한 인공신경망의 과적합에 대한 방지책은 정규화다. 학습 데이터의 개수가 적어 데이터의 일부를 검증 데이터셋과 테스트 데이터셋으로 할당하기 힘든 경우 권장되는 방법이다. 식 (30) 의 MSE는 일반적인 인공신경망의 손실함수로 채택되는 함수이다. 이 때 손실함수에 모든 가중치 및 편향의 제곱합을 추가하는 방법으로도 과적합을 방지할 수 있다. Foresee와 Hagan(1997)은 베이시안 정규화(Bayesian Regularization)를 인공신경망 학습에 활용하는 연구를 수행했다. 여기서 손실함수는 MSE와 가중치 및 편향의 제곱합을 선형결합한 함수이며, 식 (31) 과 같다.

$$F = \alpha * \sum w_i^2 + \beta * \sum (y_j - y'_j)^2 = \alpha E_W + \beta E_D$$
(31)

α, β는 목적함수 파라미터(Objective function parameter)이다. α의 상대적인 크기가 커지면 추정한 결과값이 완만하게 변화하기 때문에 과적합을 방지할 수 있는 장점이 있지만, 추정값 y'과 목표치인 yj 간의 차이가 커질 우려가 있다. α의 상대적인 크기가 작은 경우, 추정값과 목표치 간의 차이는 작아지겠지만, 가중치에 대한 제한이 약해지기 때문에 과적합이 발생할 우려가 존재한다. 따라서 인공신경의 학습에 베이시안 정규화를 도입할 때 목적함수 파라미터 α, β의 값을 정하는 것이 중요한 과제다. 이에 대한 해결책으로 MacKay(1992)는 Bayes' rule을 적용하여 α, β을 계산하는 방법을 제시하였다.

가중치와 편향을 랜덤변수라고 하였을 때, 데이터 D가 주어지면 인공신경망 내 모든 가중치와 편향의 벡터 <u>w</u>는 Bayes' rule에 따라 식

(32) 와 같은 확률분포함수를 가진다.

$$P(\underline{w}|M,\alpha,\beta,D) = \frac{P(D|\underline{w},\beta,M) * P(\underline{w}|\alpha,M)}{P(D|\alpha,\beta,M)}$$
(32)

M은 인공성경망 모델을 지칭한다. *P*(*D*|*w*,*β*,*M*)는 가능도(Likelihood function)로, 가중치 벡터 *w*가 주어졌을 때, 데이터가 발생할 확률을 뜻한다. *P*(*w*|*α*,*M*)는 사전확률(Prior density)로, 데이터가 주어지기 전에 가중치 *w*에 대한 사전확률에 대한 함수이다. *P*(*D*|*α*,*β*,*M*)는 정규화 상수의 역할을 한다. 여기서 *P*(*D*|*w*,*β*,*M*)와 *P*(*w*|*α*,*M*)가 가우시안 분포(Gaussian distribution)를 따른다고 가정하면, 각 확률밀도함수를 식 (33) 과 식 (34) 와 같이 표현할 수 있다.

$$P(D|\underline{w},\beta,M) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D)$$
(33)

$$P(\underline{w}|\alpha, M) = \frac{1}{Z_W(\alpha)} \exp(-\alpha E_W)$$
⁽³⁴⁾

이 때, $Z_D(\beta) = \left(\frac{\pi}{\beta}\right)^{0.5n}$, $Z_W(\alpha) = \left(\frac{\pi}{\alpha}\right)^{0.5N}$ 이며, n은 학습 데이터의 개수, N은 가중치와 편향의 총 개수이다. $P(D|\alpha,\beta,M)$ 이 정규화 상수가 역할을 수행할 수 있다는 점을 감안하여 사후확률 $P(\underline{w}|M,\alpha,\beta,D)$ 을 식 (35) 과 같이 정의할 수 있다.

$$P(\underline{w}|M,\alpha,\beta,D) = \frac{1}{Z_F(\alpha,\beta)} \exp(-\alpha E_W - \beta E_D)$$

$$= \frac{1}{Z_F(\alpha,\beta)} \exp(-F)$$
(35)

식 (33) ~식 (35) 을 이용하여 목적함수 파라미터를 최적화하기 위한 식 (36) 을 풀 수 있다.

$$P(\alpha,\beta|M,D) = \frac{P(D|\alpha,\beta,M) * P(\alpha,\beta|M)}{P(D|M)}$$
(36)

식 (36) 의 사전확률 *P*(*α*,*β*|*M*)을 균일 밀도라고 가정할 때, 가능도 *P*(*D*|*α*,*β*,*M*)를 최대화하는 것은 사후확률 *P*(*α*,*β*|*M*,*D*)를 최대화하는 것을 의미한다. *P*(*D*|*α*,*β*,*M*)가 증가함에 따라 식 (32) 도 값이 낮아진다. 이는 곧 손실함수가 낮아지고 가중치 벡터가 최적화된 값에 가까워지는 것을 의미한다.

식 (33) ~ 식 (35) 을 결합하여 P(D|α,β,M)의 식을 얻을 수 있다.

$$P(D|\alpha,\beta,M) = \frac{Z_F(\alpha,\beta)}{Z_D(\beta) * Z_W(\alpha)}$$
(37)

Z_F(α,β) 은 테일러 시리즈 전개를 통해 근삿값을 구할 수 있다. 손실함수는 가중치 벡터 <u>w</u>에 대한 함수이기 때문에, 최적화된 <u>w</u>^{MP} 인근의 F는 이차함수와 유사한 형상을 가진다고 할 수 있다. 이를 고려한 Z_F(α,β)의 근삿값은 식 (38) 과 같다.

$$Z_F(\alpha,\beta) \approx (2\pi)^{0.5N} * \left[det \left\{ \left(\underline{\underline{H}}^{MP} \right)^{-1} \right\} \right]^{-0.5} * exp\{-F(\underline{\underline{w}}^{MP})\}$$
(38)

$$\underline{\underline{H}}^{MP} = \alpha \nabla^2 E_W + \beta \nabla^2 E_D \tag{39}$$

식 (38) 를 식 (37) 에 대입하여 α,β 각각에 대하여 미분하여 극소점을 찾으면 최적화된 α,β을 구할 수 있다.

$$\gamma = N - 2\alpha^{MP} * tr\left(\underline{\underline{H}}^{MP}\right)^{-1}$$
(40)

$$\alpha^{MP} = \frac{\gamma}{2E_W(\underline{w}^{MP})} \tag{41}$$

$$\beta^{MP} = \frac{n - \gamma}{2E_D(\underline{w}^{MP})} \tag{42}$$

 γ 는 effective number of parameters라고 하며, 인공신경망 내의 파라미터들 중 실질적으로 E_D 을 얼마나 많은 파라미터가 사용되는지를 판단하는 척도가 된다. 앞의 과정으로 구한 손실함수 L을 최적화하는 과정에는 Hagan과 Menhaj(1994)가 제안한 Levenberg-Marquardt 알고리즘(LM 알고리즘)이 활용된다. 이를 위해 MATLAB Deep Learning Toolbox를 이용하였으며, 상세한 과정은 그림 13 과 같다.



그림 13. 인공신경망의 학습 알고리즘

'Initialization of parameters'에서는 목적함수 파라미터 α,β, 가중치 및 편향 등과 같은 주요 파라미터들을 Nguyen와 Widrow(1990)이 제시한 방법에 입각하여 초기화한다.

'Computation of error and Jacobian matrix' 단계에서는 LM 알고리즘에 따라 가중치벡터를 업데이트할 때 필요한 오차벡터 <u>e</u>^(k)와 가중치 벡터 <u>w</u>^(k)에 대한 Jacobian 행렬 J(<u>w</u>^(k))을 계산한다. 이 때, <u>e</u>^(k), <u>w</u>^(k)등의 위 첨자 (k)는 가중치 벡터 업데이트의 반복횟수를 나타낸다. 위 식에서 e와 Jacobian 행렬 J는 각각 식 (43), 식 (44) 와 같다.

$$e_i = y_i - y'_i \ (1 \le i \le n) \tag{43}$$

$$J_{ij} = \frac{\partial e_i}{\partial w_j} \quad (1 \le j \le N) \tag{44}$$

이 때 damping factor μ 는 'Initialization of parameters' 에서 초기화된 상태이다. 앞서 구한 값들을 바탕으로 가중치 벡터 $\underline{w}^{(k)}$ 를 식 (45) 와 같이 업데이트할 수 있다.

$$\underline{w}^{(k+1)} = \underline{w}^{(k)} + \left[J^T(w^{(k)})J(w^{(k)}) + \mu I\right]^{-1}J^T(w^{(k)})\underline{e}^{(k)}$$
(45)

'Calculation of α,β' 에서는 새롭게 업데이트 된 <u>w</u>^(k+1)을 식 (40)
 ~ 식 (42) 에 대입하여 목적함수 파라미터 α,β를 계산한다.

'Computation of Loss function' 에서는 새로 계산한 α,β와 식 (45) 로 업데이트한 가중치 벡터 <u>w</u>^(k+1)로 손실함수 F(<u>w</u>^(k+1))를 계산한다. 만약 F(<u>w</u>^(k+1)) 가 기존의 F(<u>w</u>^(k)) 보다 낮다면 가중치 벡터 <u>w</u> 가 손실함수를 최적화하는 방향으로 업데이트 되고 있다는 것을 의미한다. 이 경우, damping factor μ가 일정 비율만큼 감소한다. 만약 F(<u>w</u>^(k+1))가 증가했다면, μ 가 일정 비율만큼 증가한다. 본 논문에서 활용한 MATLAB Deep Learning Toolbox에서는 이 일정 비율을 10으로 설정하였다.

위와 같은 과정을 다음 5가지 조건 중 1개 이상을 충족할 때까지 반복한다.

1) 반복횟수 k가 최대 횟수에 도달한다.

2) 소요시간이 최댓값을 초과한다.

3) $F(w^{(k)})$ 가 특정한 값 이하가 된다.

4) $F(w^{(k)})$ 의 변화량이 특정한 값 이하가 된다.

5) Damping factor μ가 일정한 값을 초과한다.

3. 적용예시

3.1. 입력값의 정의

변환행렬을 작성하거나 응력 전달함수를 추정하기 위한 인공신경망을 학습시키기 위해서 선박 모델에 대한 수치해석이 필요하다. 따라서 본 논문에서는 그림 2 에 제시된 순서도와 같이 검증과정을 위한 선박의 FE 모델을 선택하였다.

검증을 위한 수치모델로는 DNV SESAM software에서 제공한 FPSO 모델을 변형한 수치모델을 사용하였다. FPSO 모델의 형상은 그림 14 와 같으며, 수치모델의 원점은 AP이다. FPSO 모델의 L(Length)는 165.8m, B(Breath)는 43m, Depth는 22.8m이다. FPSO 모델에 대한 운동해석 및 구조해석은 DNV SESAM software로 수행하였다. 두 해석 모두 0.025, 0.05, …, 1.5 (rad/s) 총 60개의 주파수와 0, 15, …,180 (deg) 13개의 회두각에 대해 수행하였다.



그림 14. FPSO의 수치모델

FPSO 모델은 이중선체 구조로 되어 있기 때문에 Ballast tank와 Cargo tank 각각에 어떻게 화물을 적재하는가에 따라 적화상태가 달라진다. 그림 2 의 '검증단계의 수립' 단계에서 추정하고자 하는 구조응답에 해당하는 적화상태인 목표 적화상태와 인공신경망의 학습 데이터에 해당하는 설계 적화상태를 구분한다. 따라서, 최소한 2가지의 적화상태가 필요하다. 따라서 Ballast tank에 ballast water을 적재한 적화상태인 LC(Loading condition)#1과 Cargo tank에 화물을 적재한 만재상태 LC#4를 우선적으로 지정하였다. 추가로 Cargo tank에 적재한 화물의 질량을 조절하여 흘수(Draft)가 LC#1과 LC#4의 흘수 사이에 오도록 조절한 LC#2, LC#3을 추가로 지정하였다. 각 적화 상태에서의 FPSO 모델의 주요 제원을 표 1로 제시하였다.

LC#	1	2	3	4
Displacement (ton)	44616	60950	84977	109000
KG (m)	7.15	11.6	11.8	11.9
Draft (m)	6.37	8.63	11.9	15.2
LCG (m)	78.6	78.6	78.6	78.6
RGxx (m)	15.7	11.5	10.6	10.8

표 1. 적화상태에 따른 FPSO 모델의 주요 제원

운동해석을 수행할 때 선체 거더 하중이 계산되는 LCS(Load cross section)을 지정한다. 그림 14 의 FPSO 모델에 x방향에 수직하도록 LCS의 위치를 지정하였다. 총 9개의 LCS를 설정하였으며, 각 LCS의 x좌표는 표 2 와 같다.

표 2. LCS의 위치

LCS #	1	2	3	4	5	6	7	8	9
X(m)	20.2	35	49.9	65	82.9	95	109.4	125	139.2

변환행렬을 계산하기 위해서 입력과 출력이 되는 계측 구조응답의 위치와 추정하고자 하는 구조응답의 위치가 필요하다. 따라서 FPSO FE 모델에서 요소들을 지정하여 가상의 LBSG 센서가 부착되었다고 가정하였다. 이후 검증과정에서 이 요소들의 해석 결과를 활용하여 변환행렬의 입력값을 계산하였다. 가상 LBSG가 부착된 요소는 총 20개이며, 그림 15 로 위치를 표시하였다.



그림 15. 가상 LBSG의 위치

그림 15 는 LBSG #1~#4와 #17~20의 위치를 표시하고 있다. 20개의 LBSG를 4개씩 묶어 5개의 그룹으로 나누었다. 각 그룹은 표 2 의 LCS#1, #3, #5, #7, #9 와 동일한 x좌표로 설정된다. 예를 들어 LBSG #1~#4와 LCS #1은 같은 x좌표를 공유한다. 이후, 동일한 x좌표를 가지는 LBSG들을 각각 Starboard deck, Starboard bottom, Port side deck, Port side bottom에 배치하였다.

변환행렬의 출력이 되는 핫스팟(Hotspot)의 위치는 midship 주위의 주요부재로 결정하였다. 동일한 종류의 부재라면 midship에서 더 큰 응력이 작용하기 때문이다. Midship 주위의 종부재(Longitudinal)에 대하여 그림 16 과 같이 fine mesh를 적용한 후 구조해석을 수행하였다.



그림 16. 핫스팟(Hotspot)의 요소(Element)

가상 LBSG의 위치의 경우와 동일하게 구조해석 결과는 검증과정에 활용하였다. 앞서 설명한 기준으로 선택한 핫스팟의 위치는 그림 17 과 같다.



그림 17. 핫스팟(Hotspot)의 위치

x방향 위치는 표 2 의 LCS #5과 동일하게 설정하였다. 파랑하중의 영향을 받지 않는 deck을 제외한 곳에 위치한 2가지의 종부재를 선택한 후, 종부재가 부착된 판(plate) 또한 구조응답을 추정할 핫스팟으로 지정하였다. 따라서 변환 행렬은 20개의 x방향 응력신호로부터 핫스팟 4곳의 x방향 응력신호를 추정하도록 계산된다.

3.2. 검증과정의 수립

그림 2 로 제시한 검증과정을 수행하기 위하여 표 1에 제시된 적화상태를 추정할 구조응답에 해당하는 목표 적화상태와 인공신경망의 학습 데이터에 해당하는 설계 적화상태로 분류할 필요가 있다. FPSO 모델은 표 1과 같이 총 4가지의 적화상태를 설정하였다. 따라서 목표 적화상태의 흘수가 설계 적화상태의 흘수 사이에 오도록 적화상태를 분류한 Case A, B를 표 3, 표 4 로 제시하였다.

표 3. 적화상태의 분류: Case A

Case A	목표 적화상태	설계 적화상태	
LC #	2	1	4
Displacement (ton)	60950	44616	109000
KG (m)	11.6	7.15	11.9
Draft (m)	8.63	6.37	15.2
LCG (m)	78.6	78.6	78.6
RGxx (m)	11.5	15.7	10.8

표 4. 적화상태의 분류: Case B

Case B	목표 적화상태	설계 적	넊 화상태
LC #	3	2	4

Displacement (ton)	84977	60950	109000
KG (m)	11.8	11.6	11.9
Draft (m)	11.9	8.63	15.2
LCG (m)	78.6	78.6	78.6
RGxx (m)	10.6	11.5	10.8

Case A에서 인공신경망은 LC#1, #4의 데이터로 학습되며, LC#2의 운동해석 결과와 인공신경망으로 추정한 응력전달함수로 그림 2 의 변환행렬 [A_{proposed}] 를 계산하였다. [A_{conventional}] 은 LC#1과 #4의 운동해석 결과와 응력전달함수로 계산한 변환행렬이며, 설계 적화상태가 2가지이기 때문에 [A_{conventional}] 또한 2가지이다.

Case B에서 [Aproposed]는 LC#3의 운동해석 결과와 인공신경망으로 추정한 전달함수로 계산되며, [Aconventional]은 LC#2과 #4의 운동해석 결과와 응력전달함수로 계산한 변환행렬이다.



그림 18. 변환모델의 검증과정

Case를 선택한 후 2종류의 변환행렬을 작성하였을 때, 추정할 대상을 그림 18 과 같이 2단계로 구분하였다. 1단계(Step 1)는 응력전달함수를 추정하여 변환모델을 검증하는 과정이다. 본 논문이 제시하는 변환행렬의 유효성을 검증을 위하여 목표 적화상태에 대한 구조해석을 수행하여 가상 LBSG 및 핫스팟의 응력전달함수를 구한다. 가상 LBSG의 응력전달함수를 2종류의 변환행렬에 입력하면 핫스팟의 응력전달함수에 대한 추정값을 얻을 수 있다. 2종류의 변환행렬로 얻은 추정값들을 구조해석으로 구한 핫스팟의 응력전달함수와 비교한다. 실제 선박에 변환행렬이 적용될 때는 입력값이 응력신호임에도 불구하고 응력전달함수로 검증을 수행하는 것은 모든 해상상태에 대한 응력신호를 만드는 것이 시간적으로 비효율적이기 때문이다. 응력전달함수가 단위파에 대한 구조응답의 크기에 대한 값임을 고려하면, 응력전달함수를 정확히 추정하는지 확인하는 것이 유의미한 검증 과정이라고 할 수 있다.

2단계(Step 2)에서는 구조해석으로 구한 응력전달함수를 바탕으로 가상 LBSG 및 핫스팟의 응력신호를 생성한다. 응력신호 생성을 위한 파 스펙트럼(wave spectrum)은 Modified PM(Pierson-Moskowitz) spectrum이며, 식 (46) 과 같다. 본 논문의 검증과정에서는 단일 회두각에 대해 응력신호를 생성하였기 때문에 spreading function에 대한 설명은 생략한다.

$$S(\omega) = \frac{(H_s)^2 * T_z}{8\pi^2} * \left(\frac{\omega * T_z}{2\pi}\right)^2 * exp\left\{\frac{1}{\pi} * \left(\frac{\omega * T_z}{2\pi}\right)^{-4}\right\}$$
(46)

위의 식에서 파스펙트럼의 주요 변수는 significant height H_s 와 zero-crossing period T_z 임을 확인할 수 있다. 주파수 ω_i 와 회두각 β_j ,

파도의 위상 φ_{ii}이 주어진 단위파에서 구조응답은 식 (46) 과 같다.

$$X_R = R_{ij} \cos(\omega_i t + \phi_{ij}) + I_{ij} \sin(\omega_i t + \phi_{ij})$$
(47)

파 스펙트럼으로 응력신호를 생성하는 경우, φ_{ij}은 0~2π 사이에서 임의로 결정된다. 위의 식을 조합하여 파스펙트럼을 따르는 구조응답을 구하면 식 (48) 과 같다.

$$X = \sum_{i=1}^{N_{\omega}} \sqrt{S(\omega_i) * \delta \omega} * X_R$$
(48)

식 (48) 을 통해 가상 LBSG 및 핫스팟의 응력신호 모두 구할 수 있다. 이 중 가상 LBSG의 응력신호를 2종류의 변환행렬 [A_{proposed}], [A_{conventional}]에 입력하면 핫스팟의 구조응답에 대한 2종류의 추정값을 구할 수 있다. 이 추정값들을 구조해석과 식 (48) 으로 계산한 핫스팟의 응력신호에 대조함으로써 검증을 수행한다. 하지만 시계열 데이터인 응력신호를 직접 비교하면 정확도를 판단하기 어렵기 때문에 Response spectrum으로 변환한 후 비교하였다.

3.3. 인공신경망의 구조 및 학습

가상 LBSG와 핫스팟의 개수가 각각 20, 4이기 때문에 그림 10 의 인공신경망 모델의 개수는 총 24개이다. 이 중 deck에 부착된 가상 LBSG와 같이 파랑하중의 영향을 받지 않는 경우 입력층에 배치한 노드의 개수는 압력을 제외한 5개가 된다.

운동해석으로 구한 선체 거더 하중 전달함수와 인공신경망으로 추정한 응력전달함수는 고유변형모드 선정 알고리즘에 입력된다. 이 때, 식 (18) 과 같이 단위파 위상 φ을 추가하여 정규파에서의 구조응답을 계산한다. 적화상태에 따라 정규파에서의 구조응답이 달라지기 때문에 본 논문에서는 이를 추정하기 위한 인공신경망을 학습시킨다. 이러한 이유로 인공신경망을 학습시킬 때, 설계 적화상태에 대한 선체 거더 하중 전달함수와 응력전달함수를 그대로 쓰는 것이 아니라 식 (18) 과 같이 단위파 위상 φ을 추가하여 학습데이터를 생성하였다. 따라서 수치해석을 수행할 때 선택한 주파수와 회두각의 개수가 각각 N_{ω} , N_{β} 이고, 단위파 위상의 개수가 N_{ϕ} 일 때, 학습 데이터의 개수는 ($N_{\omega} *$ $N_{\beta} * N_{\phi} * N_{LC}$)이다. N_{LC} 는 설계 적화상태의 개수이며 Case A, Case B 모두 2이다. FPSO 모델의 경우 $N_{\omega} = 60$, $N_{\beta} = 13$ 이며, $N_{\phi} = 40$ 으로 설정하였기 때문에 학습 데이터의 개수는 총 62400개가 된다.

3.4. 변환행렬의 계산

표 3 의 Case A에서는 본 논문이 제시한 방법으로 계산한 변환행렬 [Aproposed]와 기존의 방법으로 계산한 변환행렬 [Aconventional] 2개, 총 3개의 변환행렬을 계산했다. [Aproposed] 는 목표 적화상태인 LC#2에 대한 선체 거더 하중 전달함수와 인공신경망으로 추정한 LC#2에 대한 응력전달함수를 활용하여 고유변형모드를 선정하여 계산된 변환행렬이다. 인공신경망은 설계 적화상태인 LC#1과 LC#4의 수치해석 결과로 학습되었다. 인공신경망이 적절하게 학습되었는지 확인하기 위하여 식 (49) 와 같이 인공신경망으로 추정한 응력전달함수와 구조해석으로 구한 응력전달함수 간의 상관계수(Correlation coefficient)를 계산하였다.

$$r = \frac{\sum[(x_i - \bar{x}) * (y_i - \bar{y})]}{\sqrt{\sum(x_i - \bar{x})^2} * \sqrt{\sum(y_i - \bar{y})^2}}$$
(49)

여기서 x는 추정값이며, y는 해석으로 구한 값이다. 상관계수 r이 1에 가까울수록 두 값이 동일하다는 것을 의미한다. 인공신경망의 구조를 결정하기 위하여 은닉층의 층수와 노드의 개수를 변경하며 3가지의 인공신경망을 학습시켰다. 각 인공신경망으로 추정한 가상 LBSG 20개의 응력전달함수에 대한 상관계수와 핫스팟 4곳의 응력전달함수에 대한 상관계수를 각각 표 5, 표 6 으로 제시하였다. 표 5, 표 6의 첫번째 행에 표시된 (a-b)은 각각 은닉층의 충수(b)와 은닉층 하나 당 노드의 개수(a)를 나타낸 것이다.

표 5. 인공신경망으로 추정한 LC#2 가상 LBSG 응력전달함수의 상관계수

Measure	(20-2)	(40 - 1)	(20-1)
1	0.682	0.709	0.680
2	0.562	0.525	0.582
3	0.872	0.873	0.878
4	0.952	0.971	0.971
5	0.985	0.988	0.988
6	0.866	0.842	0.891
7	0.968	0.970	0.972
8	0.925	0.922	0.926
9	0.952	0.958	0.959
10	0.928	0.934	0.939
11	0.852	0.869	0.900
12	0.979	0.983	0.986
13	0.983	0.989	0.991

14	0.993	0.994	0.994
15	0.951	0.957	0.957
16	0.812	0.836	0.829
17	0.984	0.987	0.989
18	0.982	0.985	0.986
19	0.982	0.984	0.986
20	0.794	0.804	0.802

표 6. 인공신경망으로 추정한 LC#2 핫스팟 응력전달함수의 상관계수

Hotspot	(20-2)	(40-1)	(20-1)
1	0.989	0.988	0.988
2	0.985	0.990	0.990
3	0.992	0.994	0.996
4	0.993	0.994	0.994

전체적으로 Midship에서 멀어질수록 상관계수가 낮아지는 경향을 보이는데, 이는 데이터의 전체적인 크기의 감소와 학습데이터의 범주에 벗어나는 목표 적화상태의 데이터가 증가함에 의한 것으로 추정된다. 또한, 3가지의 인공신경망으로 추정한 결과 중 유의미한 수준으로 해석결과와 가까운 인공신경망이 없었다. 따라서 인공신경망의 구조는 1층의 은닉층에 20개의 노드를 가지는 구조로 결정하였다. 이는 구조가 단순할수록 인공신경망 학습속도가 빠르기 때문이다.

혼동을 방지하기 위하여 Case A에서 [Aproposed]는 'PROP', 2가지의 [Aconventional] 중 LC#1의 수치해석 결과로 고유변형모드를 선정하여 계산한 변환행렬을 'CONV#1', LC#4의 수치해석 결과로 계산한 변환행렬을 'CONV#4'로 명명하였다. 이대영(2022)이 제시한 알고리즘을 사용하였고, 고유변형모드의 개수는 7~13 사이에서 최적화되었다.

위의 내용에 따라 선택된 고유변형모드를 표 7~표 9 로 제시하였다.

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.575	0	61.7
2	1.425	75	72.0
3	0.75	135	308.6
4	0.85	45	267.4
5	0.725	60	113.1
6	0.75	120	349.7
7	0.6	165	216.0
8	0.8	30	174.9
9	1.275	105	205.7
10	0.75	150	82.3
11	0.8	45	185.1
12	0.75	60	329.1
13	0.625	135	144.0

표 7. Case A CONV#1의 고유변형모드

표 8. Case A CONV#4의 고유변형모드

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.65	150	41.1
2	0.625	45	102.9
3	0.575	105	339.4
4	0.725	30	185.1
5	0.8	45	246.9
6	0.725	135	92.6
7	0.65	45	123.4
8	0.65	30	226.3
9	0.825	45	20.6
10	0.625	30	277.7
11	0.7	45	51.4
12	0.625	45	123.4

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.8	135	329.1
2	0.6	0	61.7
3	0.85	45	257.1
4	0.6	180	30.9
5	0.7	135	360.0
6	0.65	45	267.4
7	0.675	45	318.9
8	0.525	150	288.0
9	1	60	82.3
10	0.675	165	267.4
11	0.6	30	51.4
12	0.925	120	82.3

표 9. Case A PROP의 고유변형모드

표 4 의 Case B도 동일하게 본 논문이 제시한 방법으로 계산한 변환행렬 [Aproposed]와 기존의 방법으로 계산한 변환행렬 [Aconventional] 2개, 총 3개의 변환행렬을 계산했다. [Aproposed]는 LC#3의 운동해석 결과와 인공신경망으로 추정한 LC#3의 응력전달함수를 활용하여 고유변형모드를 선정하여 계산된 변환행렬이다. 응력전달함수 추정을 위한 인공신경망은 LC#2과 LC#4의 수치해석 결과로 학습되었다. Case A와 동일하게 3가지 인공신경망의 구조를 설정하고 각 인공신경망으로 추정한 응력전달함수와 구조해석으로 구한 응력전달함수 간의 상관계수를 표 10~ 표 11 에 표시하였다.

표 10. 인공신경망으로 추정한 LC#3 가상 LBSG 응력전달함수의 상관계수

Measure	(20-2)	(40-1)	(20-1)
1	0.778	0.781	0.774
2	0.818	0.798	0.754

3	0.943	0.948	0.955
4	0.967	0.974	0.974
5	0.987	0.989	0.989
6	0.951	0.955	0.949
7	0.980	0.985	0.984
8	0.933	0.944	0.936
9	0.964	0.965	0.965
10	0.976	0.973	0.968
11	0.964	0.967	0.966
12	0.985	0.989	0.988
13	0.993	0.994	0.995
14	0.997	0.997	0.996
15	0.976	0.976	0.975
16	0.903	0.902	0.900
17	0.988	0.988	0.989
18	0.991	0.993	0.993
19	0.988	0.991	0.989
20	0.891	0.908	0.901

표 11. 인공신경망으로 추정한 LC#3 핫스팟 응력전달함수의 상관계수

Hotspot	(20 - 2)	(40 - 1)	(20-1)
1	0.985	0.985	0.985
2	0.996	0.996	0.996
3	0.997	0.997	0.997
4	0.994	0.995	0.993

Case B 또한 인공신경망의 구조가 상관계수에 큰 영향을 끼치는 것이 아님을 확인하였다. 따라서 20개의 노드를 가진 1층의 은닉층으로 인공신경망의 구조를 결정했다.

위의 과정을 통해 선정된 2가지의 [A_{conventional}]과 [A_{proposed}] 의

고유변형모드를 표 12 ~표 14 로 표시하였다. 이 중 본 논문에서 제시한 방법으로 고유변형모드를 선택한 [A_{proposed}] 는 'PROP', LC#2의 수치해석 결과에서 고유변형모드를 선택한 변환행렬을 'CONV#2', LC#4의 수치해석 결과에서 고유변형모드를 선택한 변환행렬을 'CONV#4' 이라 명명했다.

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.65	15	226.2
2	0.675	150	113.1
3	0.625	180	61.7
4	0.7	45	144
5	0.8	120	174.9
6	0.9	135	339.4
7	0.55	135	92.6
8	0.825	45	349.7
9	0.875	45	72
10	0.6	30	30.9
11	0.725	60	144
12	0.65	150	360

표 12. Case B CONV#2의 고유변형모드

표 13. Case B CONV#4의 고유변형모드

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.65	150	41.1
2	0.625	45	102.9
3	0.575	105	339.4
4	0.725	30	185.1
5	0.8	45	246.9
6	0.725	135	92.6

7	0.65	45	123.4
8	0.65	30	226.3
9	0.825	45	20.6
10	0.625	30	277.7
11	0.7	45	51.4
12	0.625	45	123.4

표 14. Case B PROP의 고유변형모드

Mode #	Freq(rad/s)	Heading(deg)	Phase(deg)
1	0.675	30	236.6
2	0.65	135	216.0
3	0.525	180	133.7
4	0.65	150	20.6
5	0.8	135	246.9
6	0.8	135	133.7
7	0.625	150	41.1
8	0.75	45	102.9

3.5. 구조응답 추정

Case A, Case B에 대하여 제2절 검증방법의 수립에서 정한 절차대로 수치해석 환경에서 구조응답을 추정함으로써 검증을 수행하였다.

Case A의 검증과정 1단계는 LC#2에 대한 핫스팟 응력전달함수를 추정한다. 'PROP', 'CONV#1', 'CONV#4' 총 3가지의 변환행렬에 LC#2에 대한 가상 LBSG의 응력전달함수를 입력하면 핫스팟 응력전달함수에 대한 3가지 추정값을 얻을 수 있다. 그림 19 와 같이 해석으로 구한 응력전달함수 (Numerical)를 x축에 배치하고, 각 변환행렬로 추정한 응력전달함수 (Estimation)를 y축에 배치한다.



그림 19. 해석결과와 추정결과의 비교

이후 식 (49) 를 통하여 3가지 추정값에 대한 상관계수를 구하여 그림 20 으로 표시하였다. 3가지 상관계수 모두 해석으로 구한 핫스팟 응력전달함수와 비교한 값이기 때문에, 3가지 상관계수 중 가장 1에 가까운 값이 해석에 의한 값을 가장 정확하게 추정했다고 할 수 있다. 본 논문이 제시하는 변환행렬이 유효한지를 확인하였다.



그림 20. Case A 핫스팟 응력전달함수 추정결과 비교(Step 1) 3가지의 상관계수 중 PROP가 4곳의 핫스팟에 대해 평균적으로 가장 1에 가까운 것을 확인하였다.

Case A의 검증과정 2단계는 LC#2에 대한 핫스팟 응력신호를 추정한다. 응력신호 생성을 위한 파 스펙트럼(Wave spectrum)은 Modified PM spectrum, $H_s = 5m$ 을 고정하고 표 15 과 같이 주요 변수를 달리한 2가지 스펙트럼으로 설정하였다. Modified PM spectrum에서 $T_P = 1.408 * T_z$ 이다.

표 15. 파 스펙트럼

Spectrum #	$\beta(deg)$	$T_z(s)$	$T_p(s)$
1	180	5.0	7.0
2	135	7.8	11.0

식 (48) 을 활용하여 파 스펙트럼과 구조해석으로 구한 LC#2의 응력전달함수로 가상 LBSG 및 핫스팟의 응력신호를 계산하였다.

'PROP', 'CONV#1', 'CONV#4' 총 3가지의 변환행렬에 가상 LBSG의 응력신호를 입력하여 핫스팟 응력신호를 추정하였다. 변환행렬이 3가지이기에 추정값 또한 3가지가 생성되었다. 3가지의 추정값과 수치해석을 통해 구한 핫스팟 응력신호(NUM)를 response spectrum으로 변환한다. 본 논문에서 제시한 변환행렬로 추정한 response spectrum (PROP)가 수치해석으로 구한 'NUM'과 가장 유사한지를 확인함으로써 검증을 수행하였다. 2가지 파 스펙트럼에 대해 3가지 추정값을 비교한 그래프를 그림 21. 그림 22 로 제시하였다.



Hotspot Stress response spectrum at Tp = 7s, head = 180 deg

그림 21. Case A, Spectrum#1에 대한 추정결과 비교(Step 2)



그림 22. Case A, Spectrum #2에 대한 추정결과 비교(Step 2) 모든 경우의 수에서 'PROP'가 수치해석으로 구한 'NUM'에 가장 가까운 것은 아니지만, 그림 21 의 #1 그래프 'CONV#1'이나 그림 22 의 #4 그래프의 'CONV#4'처럼 'NUM'에 극단적으로 멀어지는 경우가 없다는 것을 확인하였다.

Case B의 검증과정 1단계는 LC#3에 대한 핫스팟 응력전달함수를 추정한다. 'PROP', 'CONV#2', 'CONV#4' 총 3가지의 변환행렬에 LC#3에 대한 가상 LBSG의 응력전달함수를 입력하면 핫스팟 응력전달함수에 대한 3가지 추정값을 얻을 수 있다. 이후 식 (49) 를 통하여 3가지 추정값에 대한 상관계수를 구하여 표 17 로 표시하였다.



그림 23. Case B 핫스팟 응력전달함수 추정결과 비교(Step 1)

기존의 방법으로 작성한 변환행렬에 대한 상관계수가 Case A에 비해 증가한 것을 확인할 수 있다. 하지만, Case B도 본 논문에서 제시한 변환행렬(PROP)이 평균적으로 해석에 의한 응력전달함수와 가깝다고 할 수 있다.

Case B의 검증과정 2단계는 LC#3에 대한 핫스팟 응력신호를 추정한다. 응력신호를 생성하기 위한 파 스펙트럼은 Case A와 동일하게 표 15 의 파 스펙트럼으로 정했다. 'PROP', 'CONV#2',

'CONV#4' 총 3가지의 변환행렬에 가상 LBSG의 응력신호를 입력하면 핫스팟 응력신호를 추정하였다. 3가지 변환행렬로 추정한 응력신호와 수치해석을 통해 구한 핫스팟의 응력신호(NUM)를 response spectrum으로 변환하여 비교한 그래프를 그림 24, 그림 25 로 제시하였다.



그림 24. Case B, Spectrum #1에 대한 추정결과 비교(Step 2)



Hotspot Stress response spectrum at Tp = 11s, head = 135 deg

그림 25. Case B, Spectrum #2에 대한 추정결과 비교(Step 2)

4. 논의

본 논문에서 제시한 고유변형모드를 선정하는 방법을 FPSO FE 모델에 적용하여 변환행렬을 작성하였다. 이 때, 인공신경망의 학습 데이터를 위한 설계 적화상태와 추정하고자 하는 응력신호에 해당하는 목표 적화상태를 설정하였다. 인공신경망을 학습시킨 후 목표 적화상태의 응력전달함수를 추정하였고, 이를 기반으로 고유변형모드를 선정한 변환행렬이 설계 적화상태의 수치해석 결과로부터 고유변형모드를 선정한 변환행렬을 수치해석 환경에서 비교하였다. 그 결과, 본 논문에서 제시한 방법으로 고유변형모드를 선정한 변환행렬이 구조응답을 더 정확하게 추정하는 것을 확인하였다.

Case A와 Case B로 설계 적화상태와 목표 적화상태를 달리하여 수치해석 환경에서 검증과정을 수행하였다. Case A는 표 1 의 적화상태 중에서 ballast condition 하나와 만재상태 하나를 설계 적화상태로 지정하고, 흘수가 설계 적화상태의 사이에 오도록 만재상태 하나를 목표 적화상태로 정했다. 그림 20 으로 기존의 방법으로 계산한 변환행렬과 본 논문이 제시한 방법으로 계산한 변환행렬의 추정결과를 비교하였다. 평균적으로 본 논문이 제시한 방법으로 계산한 변환행렬의 추정결과가 정확한 것을 확인하였다. 표 5 에서 인공신경망으로 추정한 응력함수의 정확도가 떨어지는 가상의 LBSG가 존재함에도 그림 20 의 결과에는 큰 영향을 끼치지 않는다는 것을 확인할 수 있다. 표 6 의 핫스팟 응력추정함수의 추정 결과는 해석 결과와 비교적 잘 맞는다는 점을

고려한다면, 변환행렬로 추정한 구조응답의 정확도는 인공신경망으로 추정한 핫스팟의 응력추정함수에 좌우된다고 할 수 있다. 기존의 방법으로 계산한 변환행렬로 추정한 결과 중 CONV#1으로 추정한 핫스팟 #2의 상관계수가 다른 경우에 비해 현격하게 낮은 것을 확인할 수 있다. 핫스팟 #2은 선체의 바닥에 위치한 그림 16 과 같은 종부재이다. LC#1은 ballast tank에 화물을 적재한 적화상태이다. 따라서 ballast 내부의 유체 역시 운동 해석 및 구조해석 결과에 영향을 미쳤을 것이다. 그러나 LC#4와 LC#2은 화물이 cargo tank에 적재되는데, 이러한 차이점이 낮은 상관계수로 이어졌다고 할 수 있다. 핫스팟의 응력 신호를 추정하는 검증과정에서도 전체적인 경향성을 확인하면 본 논문의 방법으로 계산한 변환행렬이 큰 차이 없이 응력신호를 추정한 것을 확인하였다.

Case B는 표 1의 적화상태 중 만재상태 3개를 선택한 후, 중간값의 흘수를 가지는 적화상태 LC#3를 목표 적화상태로 지정하였다. 나머지 2개의 적화상태 LC#2, LC#4에 대한 수치해석 결과로 인공신경망을 학습시켰다. 그림 23 에서 기존의 방법과 본 논문이 제시한 방법으로 계산한 변환행렬을 비교하였을 때, Case A와 동일하게 본 논문의 방법으로 고유변형모드를 선정한 변환행렬로 추정한 구조응답이 평균적으로 해석에 의한 결과와 잘 맞는 것을 확인하였다. 모든 경우에 대해 우위에 있다고 할 수는 없지만 그림 23 에서 CONV#4의 핫스팟 #4와 같이 해석결과와 크게 차이나는 경우가 없는 것을 확인할 수 있다. 핫스팟 #4는 그림 17 에서 선측에 위치한 부재다. 표 1 의 각

적화상태에서의 주요 제원과 운동해석을 위한 패널모델을 참고하면, LC#4에서만 핫스팟 #4가 파랑하중의 영향을 받는 것을 알 수 있다. 파주파수 영역에서의 구조응답에서 파랑하중이 유의미한 수준의 영향을 끼친다. 이러한 차이점이 CONV#4로 추정한 핫스팟 #4의 구조응답이 수치해석 결과와 가장 다르게 된 원인이라고 할 수 있다. 그림 24 와 그림 25 과 같이 본 논문의 방법으로 계산한 변환행렬이 극단적인 차이 없이 핫스팟 응력신호를 추정한 것을 확인하였다. 이는 응력전달함수을 추정하는 과정에서 확인한 경향성이 반영된 것임을 알 수 있다.

5. 결론

본 논문에서는 인공신경망과 고유변형모드를 활용하여 제한된 개수의 계측 구조응답으로부터 미계측 위치의 선체구조응답을 추정하는 변환 모델에 대한 연구를 수행하였다. 정규파에서의 구조응답으로 고유변형모드를 선택한 변환모델은 다른 종류의 해석 결과에서 고유모드를 선택한 변환모델보다 파주파수에서의 구조응답을 정확하게 추정한다. 그러나 변환모델에 해당하는 적화상태와 추정하고자 하는 구조응답에 해당하는 적화상대가 다른 경우 변환 모델의 정확도가 떨어지는 한계점을 가진다. 이는 변환행렬을 계산할 때 요구되는 운동해석과 구조해석의 결과가 적화상태에 따라 달라지기 때문이다.

따라서 본 논문에서는 운동해석과 구조해석의 결과로 학습된 인공신경망으로 구조해석 결과를 추정하였다. 추정된 구조해석 결과와 실제 적화상태에 해당하는 운동해석 결과로부터 고유변형모드를 선택하여 변환행렬을 계산하였다. 본 논문은 위와 같은 방법으로 계산한 변환행렬을 수치 영역에서 검증하였다.

검증과 변환행렬 계산을 위한 수치모델은 DNV에서 제공한 FPSO 모델을 변형하여 활용하였다. FPSO 모델에 가상의 LBSG가 부착되어 있다고 가정하고 계측위치와 구조응답을 추정하고자 하는 핫스팟을 지정하였다. 핫스팟의 위치는 응력이 집중되기 쉬운 부재로 선택하였다. 추정하고자 하는 구조응답에 해당하는 적화상태인 목표 적화상태와 설계 적화상태를 구분하고, 각 적화상태에 해당하는 수치해석을 수행하였다.

변환행렬을 계산하는 기존의 방법과 본 논문의 방법을 비교하기 위하여 2종류의 변환행렬을 계산하였다. 전자의 방법에서는 설계 적화상태의 수치해석 결과에서 고유변형모드를 선택하고 변환행렬을 계산한다.

검증을 위하여 앞서 정한 핫스팟의 구조응답을 추정하는 과정을 수행하였다. 우선, 수치해석을 통해 목표 적화상태의 응력전달함수를 계산하였다. 변환행렬에 계측위치의 응력전달함수를 입력하여 핫스팟 응력전달함수를 추정하였다. 변환행렬이 2종류이기에 추정값도 2종류가 계산되었는데, 이들을 수치해석으로 구한 핫스팟 응력전달함수와 비교하였다. 상관계수로 해석결과와 일치하는 정도를 확인하였고, 본 논문에서 제시한 방법으로 계산한 변환행렬로 핫스팟 응력전달함수를 추정했을 때 정확도가 개선된 것을 확인하였다.

추가 검증을 위하여 목표 적화상태의 핫스팟 응력신호를 추정하는 과정을 수행하였다. 특정한 파 스펙트럼을 지정하고 목표 적화상태에 해당하는 수치해석 결과를 활용하여 계측 위치와 핫스팟의 응력 신호를 계산하였다. 2종류의 변환행렬에 계측 위치의 응력 신호를 입력하여 핫스팟 응력신호를 추정하였다. 이 2종류의 응력신호를 response spectrum으로 변환하여 수치해석으로 구한 response spectrum과 비교하였다. 응력전달함수를 추정하는 과정과 동일하게, 본 논문의 방법으로 계산한 변환행렬이 기존의 방법으로 계산한 변환행렬에 비해 극단적인 차이 없이 응력신호를 추정한 것을 확인하였다. 위의 검증과정을 통해 본 논문이 제시한 변환모델이 타당한 것을 확인하였다. 본 논문에서는 파주파수 영역의 구조응답을 추정하기 위한 변환모델을

개선하기 위한 연구를 수행했다. 따라서 진동 등이 포함된 고주파수 영역의 구조응답을 추정하기 위한 연구를 수행하면 본 논문에서 제시한 변환모델의 적용범위를 확장할 수 있을 것이다. 변환모델의 정확도는 고유변형모드를 선택할 때 입력되는 수치해석 결과와 직결된다. 따라서 구조해석 결과를 추정하는 인공신경망의 정확도를 향상시키기 위한 연구 역시 변환모델로 추정한 구조응답의 정확도를 높이는데 기여할 수 있다.

참고 문헌

- Barhoumi, M. & Storhaug, G., 2017. Assessment of whipping and springing on a large container vessel. International Journal of Naval Architecture and Ocean Engineering, 6(2), 442-458.
- [2] Baudin, E., Bigot, F., Derbanne, Q., Sireta, F. X. and Quinton E., 2013. Increasing ULCS Structural Response Knowledge Through 3DFEM and a Comprehensive Full-Scale Measurement System. In Proceedings of the 23rd International Offshore and Polar Engineering, June 30-July 4, Anchorage, Alaska, USA.
- [3] Bigot, F., Derbanne, Q. and Baudin, E., 2013. A Review of Strains to Internal Loads Conversion Methods in Full Scale Measurements. In Proceedings of the PRADS2013, October 20- October 25, Changwon, Korea.
- [4] Bigot, F., Sireta, F. X., Baudin, E., Derbanne, Q., Tiphine, E. and Malenica, S., 2015. A Novel Solution to Compute Stress Time Series in Nonlinear Hydro-Structure Simulations, In Proceedings of the ASME 2015 34th International Conference on Ocean, Offshore and Arctic Engineering, May 31-June 5, 2015, St. John's, Newfoundland, Canada.
- [5] Chang, C., Lin, T., Chang, C. 2018. Applications of neural network models for structural health monitoring based on derived modal properties. Measurement : Journal of the International Measurement Confederation, 129, 457-470.
- [6] D. Nguyen, B. Widrow, 1990. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. Proceedings of the IJCNN, 3, 21–26,
- [7] Dan Foresee, F., Hagan, M. (1997). Gauss-Newton approximation to Bayesian learning. Proceedings of International Conference on Neural Networks (ICNN'97), 3, 1930-1935.
- [8] DNV Classification Notes No. 30.7 Fatigue Assessment of Ship Structures. Edition April (2014)

- [9] Hagan, M., Menhaj, M. 1994. Training feedforward networks with the Marquardt algorithm. IEEE Transactions on Neural Networks, 5(6), 989-993.
- [10] Kim, H., Jang, B., Park, C., & Bae, Y. 2018. Fatigue analysis of floating wind turbine support structure applying modified stress transfer function by artificial neural network. Ocean Engineering, 149, 113-126.
- [11] Kobayashi, M., Jumonji, T., Murayama H. 2019. Threedimensional Shape Sensing by Inverse Finite Element Method based on Distributed Fiber-optic Sensors. In 14th International Symposium on Practical Design of Ships and Other Floating Structures, September 22-26, Yokohama, Japan.
- [12] L. Moreira, C. Guedes Soares, 2020. Neural network model for estimation of hull bending moment and shear force of ships in waves, Ocean Engineering, 206, 107347
- [13] MacKay, D. 1992. Bayesian Interpolation. Neural Computation, 4(3), 415-447.
- [14] MATLAB, 2022. Deep Learning Toolbox User's Guide. The MathWorks, Inc.
- [15] Tygesen, U. T., Jepsen, M. S., Vestermark, J., Dollerup, N. and Perdersen, A., 2019. The true digital twin concept for fatigue reassessment of marine structures. In 14th International Symposium on Practical Design of Ships and Other Floating Structures, September 22-26, Yokohama, Japan.
- [16] van der Meulen, Frank, Remco Hageman. Fatigue Predictions Using Statistical Inference Within the Monitas II Project. In 23rd International Offshore and Polar Engineering Conference, June 30-July 4, Anchorage, Alaska, USA.
- [17] 이대영, 2022. Hull Structural Response Prediction using Distortion Base Modes. (석사학위, 서울대학교 대학원). dCollection

Abstract

Development of conversion matrix based hull structural response prediction method by artificial neural network and distortion base modes

Joon-Hyuk Yang Naval Architecture & Ocean Engineering The Graduate School Seoul National University

Some researchers in the marine industry have developed a method for monitoring hull structural integrity in recent days. This is because design process for hull structural integrity, such as regulations, is based on statistical data and has uncertainty. Therefore, the hull integrity monitoring technology structure using real-time measurement data is required. The methods based on the concept of a digital twin that projects a real ship into a virtual space have been investigated by several researches. The purpose of these methods is estimation of overall structural response from limited number of measurement data. To achieve this goal, some researches have been conducted to calculate the conversion model by assuming the hull
structure response as a linear combination of the intrinsic mode structure response.

This paper proposes a numerical model that estimates the structural response of unmeasured locations from on-board measurement data. In this case, the conversion model assumes the base mode superposition. The accuracy of the conversion model varies if loading condition of numerical model differs to the actual one. In order to improve the accuracy of the conversion model, the proposed model applied the artificial neural network model which is trained to estimate the structural analysis result from the motion analysis results. The proposed model was validated on the numerical environment. Validation is conducted by comparing the structural responses estimated by the conversion model to those estimated by the proposed model.

Keywords : Hull structural integrity, Base mode superposition, Artificial neural network, Digital twin, Conversion model Student Number : 2021-28246