

신경망을 이용한 유조선 기름 유출사고에 따른 환경비용 추정에 관한 연구

신성철* · 배정훈* · 김현수* · 김성훈* · 김수영* · 이종갑**

*부산대학교 조선해양공학과

**한국해양연구원

Estimation of Environmental Costs Based on Size of Oil Tanker Involved in Accident using Neural Network

Sung-chul Shin*, Jeong-hoon Bae*, Hyun-soo Kim*, Seong-hoon Kim*, Soo-young Kim* and Jong-kap Lee**

*Department of Naval Architecture and Ocean Engineering, Pusan National University, Busan, Korea

**Maritime & Ocean Engineering Research Institute, KORDI, Daejeon, Korea

KEY WORDS: Neural network 신경망, Backpropagation 역전파, Risk-based ship design 위험도 기반 선박설계, Oil spill 기름 유출, Cost-benefit analysis 비용-편익 분석

ABSTRACT: The accident risks in the marine environment are increasing because of the tendency to build faster and larger ships. To secure ship safety, risk-based ship design (RBSD) was recently suggested based on a formal safety assessment (FSA). In the process of RBSD, a ship designer decides which risk reduction option is most cost-effective in the design stage using a cost-benefit analysis (CBA). There are three dimensions of risk in this CBA: fatality, environment, and asset. In this paper, we present an approach to estimate the environmental costs based on the size of an oil tanker involved in an accident using a neural network. An appropriate neural network model is suggested for the estimation, and the neural network is trained using IOPCF data. Finally, the learned neural network is compared with the cost regression equation by IMO MEPC 62/WP.13 (2011).

1. 서 론

최근 전 세계적인 물동량의 증가에 따라 선박의 고속화/대형화로 인해 해양 사고의 위험이 증가하였으며, 인명 손실 및 해양 오염에 대한 관심이 높아지고 있다. 이에 따라 IMO(International maritime organization)에서는 위험도 분석과 비용-편익 분석을 바탕으로 한 공식 안전성 평가(FSA, formal safety assessment) 절차를 기초로 기존의 규칙 기반 설계(Rule based design)가 아닌, 확률을 기초로 하는 위험도 기반 선박설계(Risk-based ship design)로 선박의 안전성을 확보하는 방안을 제안하였다(IMO, 2002). 국내에서는 위험도 기반 선박설계 방법론에 대한 연구가 활발하게 진행되고 있으며 FSA와 시스템 기능 위험성 평가 기반으로 위그선의 안전성을 평가한 예가 있다(이순섭 등, 2010).

비용-편익 분석은 위험도 기반 선박설계 시 위험도 제어 방안(Risk control option)에 대한 각각의 비용과 편익을 계산하는 과정이며 최종 설계안 결정을 위한 기준이 된다(IMO, 2007a). 비용-편익 분석 시, 편익은 인명, 환경, 자산의 차원으로 분류되며(IMO, 2007b), 그 중 환경차원에서 유조선의 기름유출과 그것에 의한 처리비용에 대한 연구가 활발히 진행되고 있다.

환경차원의 편익을 추정하는 기준으로 기름유출량에 대한 환경 처리비용의 선형추정식인 CATS(Cost to avert a tonne of oil spilled)에 대하여 연구를 수행한 경우가 있었으나(Vanem et al., 2008; IMO, 2010; IMO, 2011b), 기름유출량에 따른 처리비용이 선형으로 비례하지 않아 실제 사고 데이터와의 오차가 있었다. 더구나 CATS는 사고규모에 따라 총 처리비용이 달라지는 것을 반영하지 못하였다. 이에 IMO(2011a)에서는 식 (1)과 같이 회귀식을 바탕으로 한 SC(Societal oil spill costs) 추정식을 제안하였고, 위험도 제어 방안의 환경에 대한 편익은 위험도 제어 방안 설치 전, 후의 SC의 차이로 규정하였다.

$$SC = F_{Assurance} \times F_{Uncertainty} \times f(V) \quad (1)$$

식 (1)에서 변수 V 는 기름유출량(ton)을 나타낸다. $F_{Assurance}$ 는 사고를 복구하기 위해 사회적으로 허용 가능한 비용에 대한 계수이며 SAFEDOR에서는 OPA90(Oil pollution act90)규칙의 비용-편익 평가를 참고하여 1.5를 제안하였다. $F_{Uncertainty}$ 는 비용추측의 불확실성에 대한 계수이고 비용추측이 정확하면 1, 비용추측이 실제 값보다 적게 측정되었다고 판단되면 1보다 큰 값을 사용한다고 명시하였다. $f(V)$ 는 실제 사고데이터를 바탕으로 식

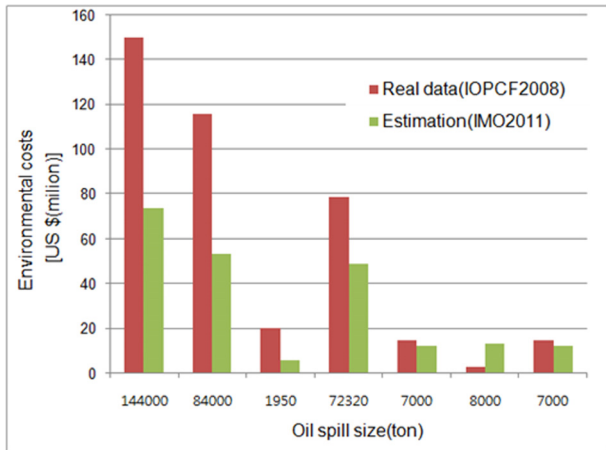


Fig. 1 Environmental costs according to oil spill size

(2)와 같이 기름 유출량에 따른 총 처리 비용을 회귀식으로 나타낸 것이다.

$$f(V) = 67,275 V^{0.5893} \quad (2)$$

IMO(2011a)에서 제시한 추정식과 IOPCF(International oil pollution compensation funds)의 실제 사고 자료(IOPCF, 2008)를 바탕으로 처리비용을 추정된 결과, 사고 자료의 결과와 추정식의 결과 값 차가 Fig. 1과 같이 최고 300%정도 차이를 보였으며, 이는 추정식의 회귀에 사용된 데이터의 산포도가 큼으로써 나타난 것으로 판단되었다.

본 연구에서는 IMO추정식의 오차를 개선하기 위해, IOPCF 자료를 바탕으로 기름 유출량에 따른 총 처리 비용을 신경망으로 모델링하여 추정하였으며, 위험도 기반 선박설계를 위한 비용-편익 분석 모델에서 환경차원의 편익을 정량화하기 위해 환경비용을 추정하는 방법을 제시하였다.

2. 환경 처리 비용 추정을 위한 신경망 모델

2.1 신경망(Neural network)

신경망은 생물학적 신경계를 단순화시켜 수학적으로 모사한 모델로 학습규칙을 사용하여 학습을 수행하는 능력을 가진다. 신경망은 주로 비선형성이 강한 데이터를 학습시켜 원하는 자료들의 패턴인식을 가능케 하는 알고리즘이다. Fig. 2와 같이 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)의




Fig. 2 Process of neural network

세 계층으로 이루어져 있으며, 입력층과 출력층 사이에는 여러 개의 계층이 존재하도록 할 수도 있다(이상원, 1995).

생물학적 뉴런들 간의 정보전달에 있어 시냅스가 중요한 역할을 담당하고 있듯이, 처리요소들 간의 연결강도를 반영하기 위해 신경회로망에서는 연결가중치(Weight) 사용하는데, 각 처리요소들은 전달받은 입력 값과 연결가중치를 사용하여 입력 값을 계산한 후 이를 이용하여 출력 값을 결정한다. 신경망은 불완전하고 잡음이 많은 입력의 해석뿐만 아니라 패턴인식 (Pattern recognition), 학습, 분류, 일반화, 추상화 등에 활용 가능하며, 대량의 데이터를 학습할 수 있다. 이로써 규칙이 알려지지 않은 상황에서의 패턴과 특성을 발견할 수 있다. 신경망의 학습은 여러 가지 방법이 있으며, 그 중 역전파(Backpropagation) 알고리즘은 순방향 다층 신경망의 학습에 효과적으로 사용할 수 있어 다양한 분야에 가장 널리 활용되고 있다. 학습규칙은 실제의 출력과 목표 출력간의 평균제곱오차(Mean squared error)를 최소화 하기위해서 연결가중치에 대한 오차의 미분계수가 감소하는 방향으로 연결 가중치를 계속 변경시키는 반복적인 경사하강(Iterative descent)알고리즘이다. 본 연구에서는 비선형성이 강한 IOPCF자료의 특성을 고려하여 역전파 알고리즘으로 다층 신경망을 학습시킴으로써 환경비용을 추정하였다.

3. 신경망을 이용한 환경 처리비용 추정

3.1 신경망의 학습

실제 기름 유출량에 따른 환경의 처리비용을 추정하기 위해, 사고 데이터는 IOPCF자료를 바탕으로 총 99개의 데이터로부터 100톤 미만사고 데이터를 제외한 59개의 데이터를 대상으로 하였다. 선종은 모두 원유운반선(Oil tanker)이며 선박의 크기는 총톤수 기준으로 최소 19 GT, 최대 146,000 GT였다. 사고와 관련해서는 최소 100톤 최대 144,000톤의 규모이다. Table 1과 같이 입력으로는 선박의 총톤수와 기름유출량, 출력으로는 사고유출량에 따른 총 처리비용 데이터를 사용하였다. 54개의 데이터를 학습데이터로 사용하였으며, 나머지 5개 데이터는 신경망 학습 후 결과를 검증하기 위한 용도로 사용하였다.

3.2 신경망의 적용

신경망의 학습률은 0.1, 에러율은 0.05, 반복횟수는 1000번으로 설정하였으며, 정확성과 효율성을 위해 Table 2와 같이 은닉층은 1개, 2개, 3개, 뉴런 수는 각 1개, 3개, 6개, 9개로 은닉층의 개수와

Table 1 Input/output for neural network

Neural network (NN)	Input layer		Output layer
	Gross tonnage of oil carrier [ton]	Agreed oil spill size [ton]	Total costs in 2009 [US \$]
For IOPCF data training		54 data	
For validation		5 data	

뉴런의 수를 달리하여 총 89개의 경우에 대하여 100여개의 자료를 바탕으로 신경망의 학습을 수행하였다.

Table 2와같이 IOPCF데이터로부터 임의로 추출한 8개 데이터와 학습된 신경망으로 추론한 결과의 값을 비교하였으며, Table 3과 같이 은닉층의 개수 별로 신경망의 추정결과가 실제 사고데이터와의 차이가 작은 값을 가지는 은닉층 및 뉴런의 조합을 각각 선정하였다. 추정의 정확도를 개선시키기 위해 선정된 신경망의 학습률을 달리하여 학습을 추가로 수행하였다. 실제 사고데이터와의 오차가 가장 적게 나타난 신경망은 Table 3에서 3.9%의 값을 가지는 신경망이며, 그 설정 값은 Table 4와 같다.

3.3 IMO추정 및 신경망을 이용한 추정 결과의 비교 분석

54척 사고 데이터를 학습한 신경망을 이용하여 5척의 학습에 사용하지 않은 검증용 데이터를 이용하여 실제 기름유출 처리비용과 IMO추정식 및 신경망에 의해 추정된 값 및 오차를 Table 5와 같이 나타냈다. Table 5에서 IMO추정식 오차값 및 신경망 추정의 오차값은 각각의 추정식에서 IOPCF 데이터값을 뺀 차이에 해당한다.

신경망에 의한 추정방법의 정확도는 IMO추정식 대비 평균

Table 2 Training cases of neural network

Number of hidden layers	One	Two		Three		
	1st.	1st.	2nd.	1st.	2nd.	3rd.
Number of neurons	5	5	1, 3, 6, 9	3	1, 3, 6, 9	1, 3, 6, 9
	6	6	1, 3, 6, 9	6	1, 3, 6, 9	1, 3, 6, 9
	7	7	1, 3, 6, 9	6	1, 3, 6, 9	1, 3, 6, 9
	8	8	1, 3, 6, 9	9	1, 3, 6, 9	1, 3, 6, 9
	9	9	1, 3, 6, 9	9	1, 3, 6, 9	1, 3, 6, 9
	10	10	1, 3, 6, 9			
Cases	5	20		64		
Total cases				89		

Table 3 The result of changes in learning factor

Results	Learning factor	Difference between NN results and IPCOF data (average percentage)				
		0.1	0.3	0.5	0.7	
Cases	Single hidden layer	1st. : 6 neurons	9.3%	8.8%	7.5%	6.3%
		Two hidden layers	1st. : 6 neurons 2nd. : 3 neurons	5.9%	4.8%	19%
	Three hidden layers	1st. : 3 neurons	4.8%	5.3%	3.9%	5.8%
		2nd. : 1 neuron 3rd. : 3 neurons				

Table 4 Neural network parameters in the best estimation case

Learning factor	0.5	
Number of neurons in hidden layer	1st.	3
	2nd.	1
	3rd.	3

Table 5 The comparison of estimation with real data. [Unit : US \$(million)]

Data for validation	Real data (IOPCF)	IMO formula	NN	Error (IMO formula)	Error (NN)
1	115.84	53.67	167.21	62.17	51.37
2	366.33	16.11	155.15	350.22	211.18
3	32.75	8.39	55.10	24.36	22.35
4	15.04	2.68	6.23	12.35	8.80
5	29.99	1.53	6.49	28.46	23.50

* Neutral network

19%정도 개선되었다. 그러나 신경망으로 추정 시 실제 처리비용과 여전히 무시할 수 없는 오차를 보이고 있다. 이것은 신경망의 학습이 아직 완전하지 않았거나, 신경망 입력변수로 사용하였던 선박의 규모와 기름유출량만으로 처리비용이 결정되지 않음을 시사한다.

3.4 유조선 적용 예

앞서 학습된 신경망을 이용한 환경비용의 추정 방법으로 위험도 기반 선박설계 시 비용-편익 분석을 적용하면 위험도제어방안에 대한 의사결정을 지원할 수 있다. 본 연구에서는 기름유출량은 IOPCF데이터의 평균 유출량인 4,800톤, 선박의 총톤수는 450,000톤으로 가정하였다. 각 위험도제어방안의 기름유출에 대한 위험저감량 값은 MEPC57/17/2(IMO, 2008)을 참고하여 나타내었으며, 위험도제어방안 설치 전, 후의 SC(Societal oil spill costs)의 차이를 IMO추정식에 의한 값을 ΔSC, 신경망에 의한 값을 ΔSCNN로 Table 6과 같이 계산하여 나타내었다. 여기서 RCO1, RCO2, RCO3, RCO4는 각각 전자해도 표시정보시스템(Electronic chart display and information system), 부두 근접도 및 속도센서(Terminal proximity and speed sensor), 고온작업 절차 개선(Better implementation of hot work procedures), 선각 응력 및 피로 모니터링 시스템(Hull stress and fatigue monitoring system)이다.

ΔSC 값과, ΔSCNN 값을 비교 보았을 때, 위험도제어방안 1의 저감효과가 두 값 모두 가장 크게 나타나며, 기름유출량에 따른 환경비용 측면에서만 보면 대안 1이 가장 이상적인 대안이라 할 수 있다. 해당 예에서는 두 가지 방법인 IMO추정식과 신경망을 이용한 추정방법 모두 동일한 대안 1의 선택을 하게 되지만 그 정량적 값의 크기는 다르므로 사고규모의 조건이 변경된다면 의사결정이 달라질 수 있어서 설계자 및 선주 등이 그 결과를 참고하여 결정해야 할 사항이다. 다시 말해서, 신경망과 IMO추

Table 6 The comparison of SC

RCO	Oil spill reduction [ton]	ΔSCNN [US \$]	ΔSC [US \$]	Rank
1	170	2,054,806	313,361	1
2	4	39,171	7,320	3
3	45	295,449	82,499	2
4	4	39,171	7,320	3

정식 모두 사고규모를 바탕으로 한 예측모델이기는 하지만 데이터에 비선형성이 강하므로 보다 다양하고 많은 위험도제어방안을 고려한다면 예측되는 위험저감량이 다양할 것이고 이에 따라 환경비용에 대한 우선순위가 바뀔 가능성이 있음에 유의해야 한다.

4. 결 론

이상의 연구 내용을 요약하면 위험도기반 선박설계를 위한 비용-편익 분석에서 환경비용 추정을 위해 신경망을 사용하였으며 이로써 54척의 사고데이터를 학습데이터로 사용하였다. 학습된 신경망으로 따로 마련한 5척의 사고데이터를 통해 유조선 기름 유출사고에 따른 환경비용의 추정을 시도한 결과, 정확도를 IMO추정방법 대비 평균 19%정도 향상시켰다. 또한 450,000톤 유조선에 그 결과를 적용하여 설계단계에서 위험도제어방안의 위험저감 효과를 정량적 혹은 경제적인 화폐가치로 나타냄으로써 가장 비용효과적인 위험도제어방안을 결정할 때 기준으로 사용 가능하였다.

그러나 본 연구에서 제안한 학습된 신경망은 IMO추정식보다는 향상되었지만 여전히 상당량의 오차를 보이고 있으므로 이에 대한 추가적인 연구가 필요하다. 보다 많은 사고데이터를 확보하고, 선박 총톤수와 기름유출량 이외의 입력변수를 다양화하며, 신경망 학습조건에 대한 보다 체계적인 결정방법 등이 향후 연구의 방향이 될 것이다.

후 기

이 논문은 부산대학교 자유과제 학술연구비(2년)에 의하여 연구되었음

참 고 문 헌

이상원 (1995), "학습하는 기계 신경망". Ohm사.

이순섭, 박범진, 이종갑 (2010). 위그선 설계단계에서의 안전성 평가, 한국해양공학회지, 제24권, 제6호, pp 103-108.

IMO (2002). Guidelines for Formal Safety Assessment (FSA) for use in the IMO rule-making process, MSC/Circ.1023, MEPC/Circ.392.

IMO (2007a). Consolidated text of the Guidelines for Formal Safety Assessment(FSA) for use in the IMO rule-making process (MSC/Circ.1023-MEPC/Circ.392), MSC 83/INF.2.

IMO (2007b). FSA - container vessels Details of the Formal Safety Assessment, MSC 83/INF.8.

IMO (2008). FSA for Crude Oil Tankers by Denmark, MEPC 58/17/2.

IMO (2010). Information on the costs of oil spills in Norwegian territorial waters and proposal for an environmental risk criteria, MEPC 60/17/1.

IMO (2011a). Consideration on the Cost of Averting a Tonne of Oil Spilled (CATS) threshold function, MEPC 62/18/4.

IMO (2011b). Report of the Working Group on Environmental Risk Evaluation Criteria within the context of Formal Safety Assessment, MEPC 62/WP.13.

IOPCF (2008). Annual report 2007. International Oil Pollution Compensation Funds, London.

Vanem, E., Endresen, Ø. and Skjong, R. (2008). Cost-effectiveness criteria for marine oil spill preventive measures, Reliability Engineering and System Safety, 93, 1354-1368.

2012년 1월 25일 원고 접수

2012년 2월 13일 심사 완료

2012년 2월 13일 게재 확정