

# 화재 위험도 예측을 위한 딥 러닝 알고리즘에 관한 연구

박병철(부산대학교), 임채욱(부산대학교), 오상진(부산대학교), 정민재(한국선급), 신성철(부산대학교)

## A study on deep learning algorithm for fire risk prediction

Byeong-cheol Park(Pusan National University), Chae-og Lim(Pusan National University),  
Sang-jin Oh(Pusan National University), Min-jae Jung(Korean Register),  
Sung-chul Shin(Pusan National University)

### 요약

선박 사고 시 사고 대응을 하기 위해서는 선장의 의사결정이 많이 요구되며, 사고 현장에서의 상황을 정확하게 파악할 필요가 있다. 또한, 사고 상황에서 사고의 위험은 주변 상황에 따라 수시로 변하기 때문에, 사고에 대응하거나 퇴선 해야 되는 상황의 위험도를 예측한다면 사고 피해를 줄일 수 있을 것이다. 따라서 실시간으로 사고 상황에서의 의사결정을 지원하기 위해서는 화재 위험도를 예측하는 것이 중요하다. 본 연구에서는 LNG 벙커링 시 이송조건 변화에 따른 사고확률과 화재 시나리오에 따른 Phast 해석결과 데이터를 신경망으로 구축하고, 학습된 결과를 연구 대상에 대입하여 위험도 결과를 비교·평가 한다. 예측된 위험도 결과를 토대로 선장의 의사결정을 지원할 수 있도록 한다.

**Keywords** : LNG 벙커링(LNG bunkering), 딥 러닝(Deep learning), 화재 위험도(Fire risk), 사고확률(Accident frequency), 사고심각성(Accident consequence)

## 1. 서론

### 1.1 연구배경

해양사고는 육상사고와 달리 외부 지원을 신속하게 받을 수 없으므로, 피해를 최소화하기 위한 자체적인 사고 대응이 매우 중요하며, 초기대응 실패하게 될 경우 2차, 3차 피해로 이어진다. 또한 신속한 상황 보고의 실패로 효과적인 긴급 사고대응을 위한 의사결정을 지원할 수 없거나 늦어지게 되면, 엄청난 인명 및 재산 손실을 유발하는 경우가 많다. 이러한 목적으로 사고의 신속한 탐지, 상황에 따른 피해의 즉각적인 예측 및 최적화된 사고대응이 필요하다.

현재 사고에 대응하기 위한 의사결정 지원 시스템은 사전 정의된 수천 개 이상의 사고 시나리오를 기초로 구성된 전산 시뮬레이션 데이터베이스를 활용하여, 사고 대응에 필요한 의사결정을 지원 및 운용체계 구성으로 빠르게 전개되는 사고 상황에 대응할 수 있도록 구성되어 있다. 이는 사고 시 비슷한 상황의 시나리오를 검색하여 선박 내부의 의사결정을 지원할 수 있지만, 현재 공정상에서의 조건 등을 고려한 사고에 대해 대응하기에는

현실적인 조건을 고려하기가 어렵기 때문에, 실시간으로 주어지는 상황에서의 조건을 고려하여 실시간으로 대응할 수 있는 방안이 필요하다.

선박에서의 사고 상황은 급박하게 이루어지게 될 가능성이 크기 때문에 위험도를 우선적으로 파악하게 되면 의사결정을 수행하는 데에 도움이 된다. 예를 들면 공정 작업을 진행 중인 상황에서 1mm의 누출이 일어났다고 가정하면, 1mm의 위험은 그렇게 위험한 상황이 아니기 때문에 충분히 대응할 수 있는 상황임에도 불구하고, 공정 가동이 중지되거나 작업자의 당황으로 인해 2차 사고의 위험 및 공정 중지에 대한 비용 등 큰 손해를 보게 된다. 그렇기 때문에 위험을 우선적으로 알게 된다면, 재산 피해, 인명 피해 등을 최소화 할 수 있을 것이다.

이에 전통적인 위험도는 새로운 설계 및 초기 설계 단계에서 위험 식별을 통해 설계상에서 위험원을 확인하여 제거하거나 예방하는 의사결정을 지원한다. 기존에는 평균 위험도를 다루며, 대상이 달라도 동일한 위험도를 적용하기 때문에, 대상의 특성을 살리지 못하고 있다. 또한, 실제 대상이 동작 중일 때 평균 위험도를 적용하게 된다면, 현재 대상의 상태가 반영되지 않아 올바르게 판단을 할 수 없다. 대상의 상황에 따라 위험도를 실시간으로 확인할 수 있다면, 해당 작업자는 위험의 정도에 따른

의사결정을 수행할 수 있다. 여기서, 기대효과는 해당 대상의 올바르게 판단에 대한 시간과 비용을 절감 할 수 있으며, 의사결정을 하는 시간을 벌 수 있기 때문에 보다 올바른 판단을 유도할 수 있다.

본 연구에서는 사고 상황 시 실시간으로 위험도를 확인할 수 있도록 하는 초기 연구로써, LNG 벙커링 중에서의 이송 조건 변화에 따른 사고 확률을 구하고, 사고 확률에 따른 사고 심각성을 확인할 수 있는 딥 러닝 알고리즘을 구축하였다.

### 1.2 관련 연구 현황

실시간 고장검출 및 진단 기법에 관한 기존의 연구는 수학적 모델을 통한 고장진단 방법, 인공지능 기법을 이용한 지식기반 진단방법, 데이터 신호 특성을 분석하여 검출하는 신호처리 진단 방법 등 다양한 방법에 대해 연구되고 있다.

Lee(2015)는 개방고장의 경우 단락고장에 비해 비교적 시스템에 미치는 영향은 적으나 방지할 경우 시스템 전반적으로 2차 고장을 야기할 수 있기 때문에 조기 고장진단 측면에서 매우 중요하다. 이에 인버터의 스위칭 동작에 따른 단락고장과 개방 고장에 대해 전류 센서 외 별도의 추가적인 하드웨어 없이 빠른 감지 특성을 갖는 고장진단 시스템을 제안하였고, 3상 PCS 스위칭 소자의 단락고장과 개방고장에 대해 모의실험을 한 후 각 특성에 대해 분석하였다. Lee(2016)는 해상용 승강기 시장에서의 경쟁력 확보를 위해서 통합 안전 관리 시스템을 도입하기 위하여, 국내외 IT 기술을 이용한 승강기 고장진단 및 통합 운용 시스템의 사례를 비교분석하고 요구사항들을 기능별로 정의하였으며, 기능 구현을 위한 시스템을 설계 및 구현하였다. 구현된 시스템에 대한 통신에 대한 객관적인 지표로 성능을 평가하였다.

Yang(2017)는 일반적으로 센서나 기계의 고장을 판별하는데 있어서 신호 처리 및 분석기법이나 퍼지 이론 등이 사용되는데, 이러한 방법들은 작업 환경의 복잡성으로 인하여 일부의 방법들만 적용가능하다는 저가용성 문제와 새로운 고장 유형이 발생할 경우에는 분석 및 대처를 위한 알고리즘의 추가 및 수정이 어렵다는 문제가 있다. 이를 해결하기 위해 딥 러닝 기법 중 하나인 Convolution Neural Network(CNN)을 적용하여, 센서에 관한 전문적인 지식 없이도 기존의 고장 데이터들을 학습하여 고장을 유형별로 분류하기 위한 최적의 모델을 제공하였고, 센서의 고장을 유형별로 분류하기 위한 CNN모델을 구현하고 CNN의 분류 성능을 높이기 위해 ensemble 기법을 사용하여 정확도를 높이는 방법을 제안하였다. 공학 분야 외에 딥 러닝을 활용한 연구가 꾸준히 증가하고 있는데, Park(2017)는 금융업계에서 활용되고 있는 딥 러닝 기술을 사례와 현황을 분석하기 위하여, 딥 러닝 기술에 대한 역사적 배경, 개념 및 원리에 대해 설명하였다.

본 연구에서는 딥 러닝 기법 중 하나인 DNN(Deep Neural Networks)를 활용하여 LNG 벙커링 중에서 일어날 수 있는 사고 확률과 사고 심각성을 예측하여, 실시간으로 LNG 벙커링 중의 위험도를 확인하여 사고대응 시 의사결정을 지원할 수 있는 도구로 사용할 수 있는 초기 연구를 진행하였다.

## 2. 딥 러닝 알고리즘 구축

### 2.1 Deep Neural Network

딥(Deep)이라는 말은 신경망의 층(Layer)이 깊고 각 층마다 고려되는 변수가 많다는 의미이다. 층의 깊이에 따라 구분하자면 수 개의 층으로 되어 있는 신경망을 2~3개의 층으로 되어 있는 신경망을 천층망(Shallow Network)이라 하고, 그 이상의 층으로 구성되어 있는 신경망을 심층망(Deep Network)이라고 한다. 딥 러닝에서 깊이를 나타내는 층의 개수는 입력층과 출력층 사이에 있는 은닉층(Hidden layer) 개수에 하나를 더하면 된다. 이러한 이유로 딥 러닝을 심층신경망 이라고도 한다(DNN: Deep Neural Network)(Park, 2017).

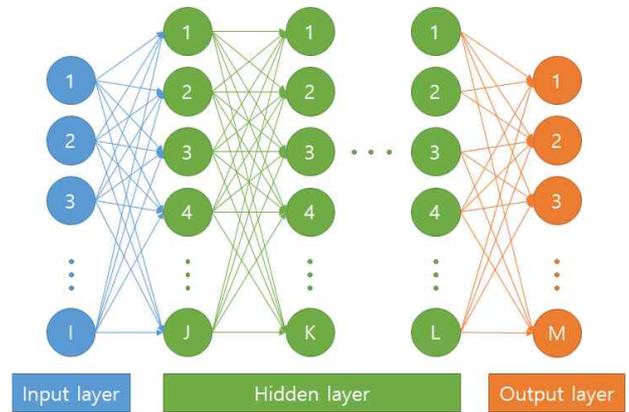


Fig. 1 Deep Neural Network

최적화 알고리즘으로 사용한 AdamOptimizer는 Tensorflow에서 제공하는 Training 알고리즘으로써 주어진 트레이닝 세트 데이터로부터 오차함수를 계산해서 그 기울기 벡터의 반대 방향으로 파라미터를 수정하는 처리를 하는 것이다. 또한 학습률 파라미터도 자동으로 조절하는 구조를 갖추어 비교적 성능이 좋고 학습률을 수동으로 조절할 필요가 없으므로 Deep learning에서 자주 이용되는 알고리즘 중 하나이다. 학습 과정을 보다 효과적으로 수행하기 위해 활성화 함수(activation function)가 동작하는 0과 1사이 값으로 데이터를 정규화 하였다(Oh, 2017, Ahn, 2003). 정규화 식은 식(1)과 같다.

$$\bar{d} = \frac{d - \min}{\max - \min} \quad (1)$$

인공신경망에서 은닉층은 두 가지 역할을 수행하는데 하나는 앞 층에서 전달받은 신호를 가중치를 고려해 선형적으로 합산하고 다른 하나는 합산된 값을 활성화 함수에 적용하여 다음 층으로 전달하는 피드포워드를 수행한다. 이 과정은 다음과 같이 입력 값이 주어질 때, 계층을 거쳐 출력 값으로 변환되는데 이때

가중치의 곱과 비선형 활성화 함수인 Sigmoid 함수를 적용하여 진행된다.

여기서 깊은 층의 DNN을 구성하게 되면 맨 위의 값이 최종값에 미치는 영향이 매우 미비해지므로, Sigmoid 함수를 사용하다 보니 0과 1사이의 값들을 계속해서 곱하게 되고, 그렇게 되다보니 값에 대한 영향력이 줄어든다는 것을 확인하였다. ReLU (Rectified Linear Unit) 함수는 Sigmoid 함수와는 다르게 0이하의 수는 다 0으로 처리하므로, DNN을 구성할 때 마지막 최종 값을 나타낸 곳에만 활성화 함수 Sigmoid 사용하고 각각의 Layer 사이의 함수에는 ReLU를 사용함으로써 영향력을 골고루 미칠 수 있게 하였다. Fig. 2는 Sigmoid 함수와 ReLU 함수를 비교한 그림이다.

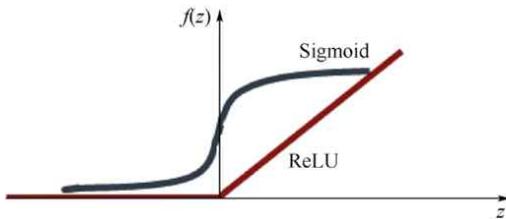


Fig. 2 Comparison of Sigmoid and ReLU function

은닉층에서 사용되는 활성화 함수의 주요 역할은 뉴런으로 모인 신호를 조금 더 변형력 있는 상태로 전환하는 것이며, 특히 임계치를 적용하여 의미 없는 데이터는 사전에 필터링을 한다. 피드포워드 신경망에서 원하는 결과를 얻기 위해서는 뉴런 사이의 정보 전달 과정에서 작용하는 적당한 가중치를 알아내야 한다. 즉 특정 패턴인식 임무를 함수라고 가정한다면 가중치를 조정하여 이 함수를 찾는 과정을 학습이라고 할 수 있다(Ahn, 2003).

## 2.2 요소 선정

본 연구에서는 요소 선정 대상은 LNG Bunker Ship에서 LNG 추진선박에 LNG를 급유하는 시스템으로 선정하였다. 시스템 내에서 급유절차는 LNG가 저장탱크에서 급유라인을 따라 LNG 추진선박의 연료탱크로 저장되고, 이때 양 탱크의 압력을 맞춰주기 위해 Vapor return 가스가 회수라인을 따라 LNG 저장탱크에 회수되는 절차로 진행된다. 여기서 급유를 시행할 때 Connection 되는 부분이 상당히 위험하여 누출로 인한 화재의 위험이 발생 가능하기 때문에 요소로 선정하게 되었다.

시스템 내의 센서로는 화재감지기, 가스감지기, 압력 전송기, 모니터링 시스템이 있으며, 차단밸브로는 볼밸브, 게이트밸브가 사용되었는데, LNG 제어용으로는 볼밸브가 LNG 급유라인에, 가스제어용으로는 게이트밸브가 가스회수라인에 배치되었다.

## 2.3 사고확률 딥 러닝 알고리즘

### 2.3.1 사고확률 데이터 생성

데이터를 생성하기 위해 ANSYS CFX 해석 프로그램을 사용하여 배관의 모델링과 해석을 수행했다. LNG 벙커링 Connection line으로 LNG Transfer pipe로 이루어져 있다. 배관의 직경은 150A 이고, 길이는 5m로 정하였다. LNG 벙커링 Connection 부분에서 누출이 발생하여, Line의 시작점과 끝점에서의 LNG Massflow, Velocity, Pressure, Leak massflow의 차이 값을 구하였다.

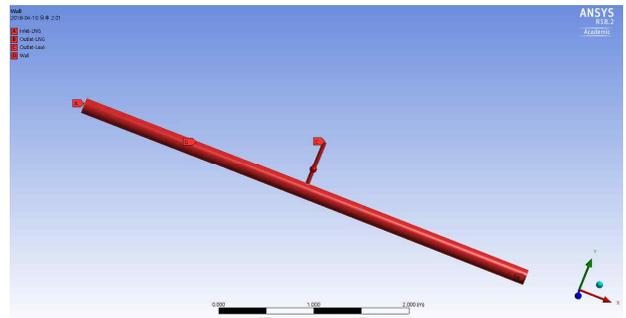


Fig. 3 LNG line modeling

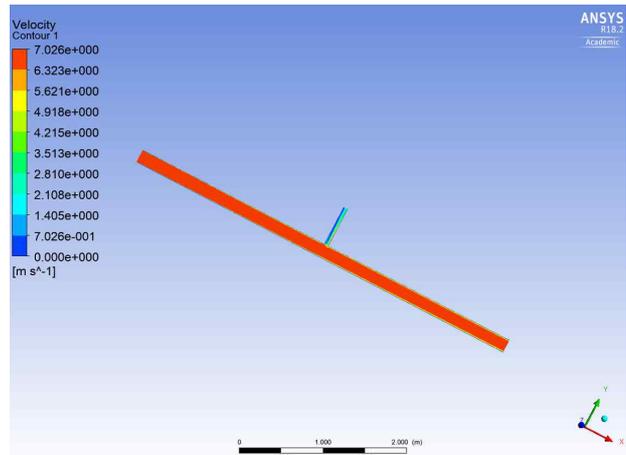


Fig. 4 Result of analysis

사고확률 딥 러닝 알고리즘 Feature들의 Input data와 Output data는 다음 Table 1과 같다.

Table 1 Input and Output data (Frequency)

	Parameter	Constraints(unit)
Input	LNG mass flow	56.2823 ~ 58.994 (kg/s)
	LNG velocity	6.20544 ~ 6.50511 (m/s)
	LNG pressure	3.78e-06 ~ 9.86e-05 (bar)
	LNG leak Mass flow	0.075415 ~ 3.45722 (kg/s)
Output	Leak hole size	10 ~ 120 (mm)

### 2.3.2 사고확률 딥 러닝 알고리즘 결과

본 연구는 구글의 Tensorflow 1.2.1을 사용하였다. 사고확률 딥 러닝 알고리즘은 Input data 4개, Output data 1개, Training data 25개, Test data 5개로 구성되어있고, 학습을 진행하기 위한 Learning rate는 0.1로 하여 50,000번의 학습을 진행하였다. Layer의 수는 5개, Neuron 수는 Layer 마다 동일하게 16개로 구성하여 Output layer가 최종적으로 1로 수렴하도록 구성하였다.

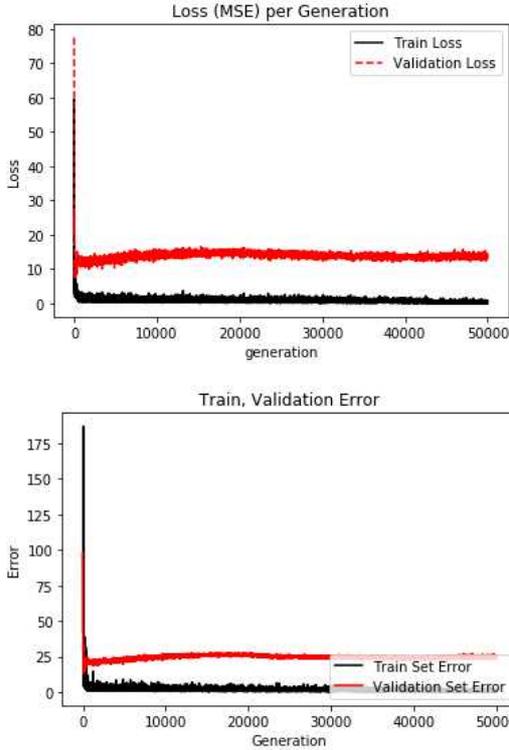


Fig. 5 Loss and Error (Frequency)

Fig. 5는 결과 그래프를 보여주며, Validation set은 수렴했지만 Training set이 학습해 갈수록 흔들림이 줄어들고 수렴하며, 수렴하는 경향도 Training set과 Validation set이 비슷하다는 것을 알 수 있다.

최종적으로 Training set, Validation set, Test set의 평균 Error는 Table 2와 같다. 오차율을 보면 Training data의 오차는 0.96%인 반면, Test, Validation data의 오차율은 24.57%, 27.64%로 높은 오차율을 보이고 있다.

Table 2 Result of Error (Frequency)

Set	Error
Training data	0.96%
Validation data	27.64%
Test data	24.57%

### 2.4 사고심각성 딥 러닝 알고리즘

#### 2.4.1 사고 심각성 데이터 생성

데이터를 생성하기 위해 Phast 7.11 해석 프로그램을 사용하여 누출 상황에 대한 화재 해석을 수행하였다. LNG 병커링 Connection line에 누출이 발생하여, 바람속도, 파공크기, 누출시간, 연료량에 따른 100가지의 시나리오를 데이터화하였다.



Fig. 6 Jet fire as distance (PHAST 7.11)

위에서 해석한 복사열량을 화재에 의한 피해 영향을 나타내는 식(2)에 대입하여 복사열량에 따른 인명 피해 영향을 계산한다.

$$Y = 12.54 - 1.847 \ln(ttf) \quad (2)$$

$$\ln(ttf) = -1.128 \ln(Q) - 2.667 \times 10^{-5} V + 9.877$$

이러한 절차로 계산된 프로빗 수는 아래 식(3)을 이용하여 백분율로 환산하였다.

$$Pd_{ij}(\%) = 50 \times \left[ 1 + \frac{Y-5}{|Y-5|} \operatorname{erf} \left( \frac{|Y-5|}{\sqrt{2}} \right) \right] \quad (3)$$

사고심각성 딥 러닝 알고리즘 Feature들의 Input data와 Output data는 다음 Table 3과 같다.

Table 3 Input and Output data (Consequence)

	Parameter	Constraints(unit)
Input	Wind speed	2.02 ~ 22.97(m/s)
	Leak hole	1.19 ~ 89.42(mm)
	Leak duration	10.78 ~ 289.47(s)
	Fuel amount	145.369 ~ 146497(kg)
Output	Heat radiation	40.43 ~ 165.06(kW/m <sup>2</sup> )

#### 2.4.1 사고 심각성 딥 러닝 알고리즘 결과

사고확률 딥 러닝 알고리즘은 Input data 4개, Output data 1개, Training data 85개, Test data 15개로 구성되어있고, 학습을 진행하기 위한 Learning rate는 0.01로 하여 1,000번의 학습을 진행하였다. Layer의 수는 7개, Neuron 수는 Layer 마다 줄여서 80, 56, 32, 16, 8, 4 순으로 구성하여 Output layer가 최종적으로 1로 수렴하도록 구성하였다.

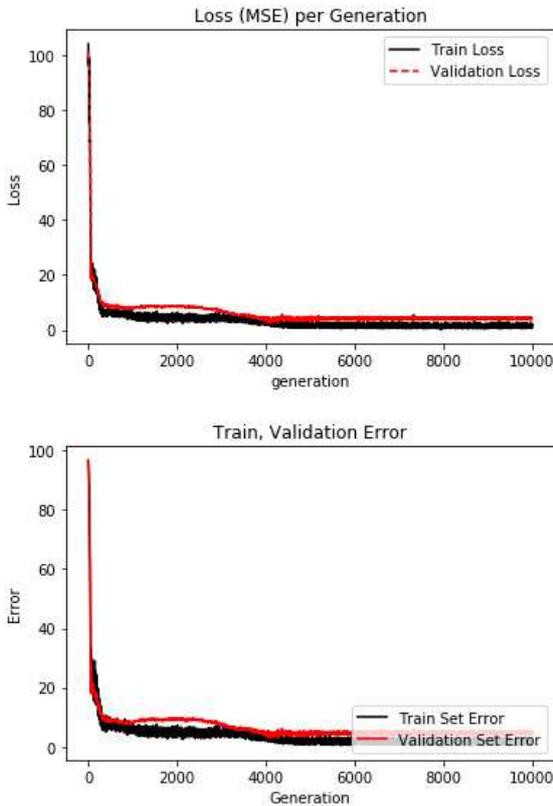


Fig. 7 Loss and Error (Consequence)

Fig. 7은 결과 그래프를 보여주며, Training set과 Validation set은 수렴하면서 두 set가 수렴하는 경향이 비슷하여, 오차율이 적을 것으로 판단하여 더 이상의 학습을 진행하지 않았다.

최종적으로 Training set, Validation set, Test set의 평균 Error는 Table 4와 같고, 확인 결과 3가지 set의 평균 오차율이 10% 미만인 것으로 확인되었다.

Table 4 Result of Error (Consequence)

Set	Error
Training	1.74%
Validation	4.98%
Test	8.08%

### 3. 결론

이상의 LNG 병커링 시스템에서의 화재 위험도 예측에 대한 딥 러닝 알고리즘 분석의 결론은 다음과 같다.

- LNG 병커링 시스템의 LNG 연료 공급 배관 및 누출을 대상으로 화재로 인한 사고를 실시간으로 확인할 수 있도록 하는 사고확률 및 사고 심각성에 대한 알고리즘에 대한 초기 연구를 진행하였다.

- 사고확률 알고리즘에서는 4개의 Input data와 1개의 Output data를 구성하였고, 사고심각성 알고리즘에서는 4개의 Input data와 1개의 Output data로 구성하였다.
- LNG 연료 공급 라인에서의 실시간 조건 변화를 통해서, 누출에 의한 파공크기를 예측하여, 사고 확률을 구하였다.
- 앞서 예측된 파공크기를 통하여, 바람, 누출시간, 연료량 등의 상황을 학습하여 화재의 심각성인 화재 복사열량을 예측하였다.
- 사고확률 딥 러닝 알고리즘의 경우에는 사고확률을 예측하기 위한 Training data와 Test data의 개수가 부족하다고 판단되며, 추가적으로 진행하게 된다면 보다 더 좋은 결과를 얻을 수 있을 것으로 보인다.
- 사고심각성 딥 러닝 알고리즘의 경우에는 평균 오차율이 10% 미만으로 Layer, Neuron의 수를 조정하게 된다면 우수한 예측률을 보일 것으로 판단된다.

현재는 실시간으로 받을 수 있는 데이터 및 고려되어야 할 Feature의 부정확하여 추가적인 검토가 필요하다. 추후 연구에는 사고확률에 대한 Feature 정의에 대해 추가하거나 수정해야 될 부분이 있는 검토하고, 배관의 조건에 따라 사고확률이 어떻게 변화되는지에 대한 연구가 필요하다. 사고심각성 부분 또한, 실시간으로 받을 수 있는 데이터를 통해 Feature들의 정의를 다시 한 번 검토 후 추가 및 수정이 필요하다. 앞으로 사고확률 및 사고심각성에 대한 데이터를 추가로 확보하여, 실시간으로 화재 위험도 변화를 정량적으로 보여줄 수 있는 연구를 수행 할 것이다.

### 후기

이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2011-0030013)

### 참고 문헌

An, H.J., 2003. Inference of Light Weight and Propeller Weight using Neuro Fuzzy System. Master's thesis. Pusan National University.

M. Elisabeth Pate-Cornell, 1993. Learning from the Piper Alpha Accident: A Postmortem Analysis of Technical and Organizational Factors. *Risk Analysis*, 13(2), pp.215-232.

Oh, S.J., Bae, J.H., Lim, C.O., Park, B.C., 2017. Predicted to Maximum Stress of Piping Using Machine Learning Algorithm. Autumn conference of the society of naval architectures of korea, pp. 368-372.

Park, W.G., 2017. Introduction to Deep Learning and Financial Application. Korea University. Master's thesis.

Ryu, S.I., 2017. Artificial Intelligence Leading the Fourth Industrial Revolution - Focusing on Deep Running. *DegiEco*

*Report No F01506822.*

Swedish Marine Technology Forum, 2010. LNG ship to ship bunkering procedure.

Yang, J.W., Lee, Y.D., Koo, I.S., 2017. A Study on Sensor Fault Data Processing Using Deep Learning. *Autumn conference of the Korean Institute of Communications and Information Sciences*, pp.20-21.