

# 딥러닝 기반의 연기 확산거리 예측을 위한 알고리즘 개발 기초연구

김별\* · 황광일\*\*†

\* 한국해양대학교 대학원 박사과정, \*\* 한국해양대학교 기계공학부 교수

## Fundamental Study on Algorithm Development for Prediction of Smoke Spread Distance Based on Deep Learning

Byeol Kim\* · Kwang-Il Hwang\*\*†

\* PhD Student, Graduate school of Korea Maritime and Ocean University, Busan 49112, Korea

\*\* Professor, Division of Mechanical Engineering, Korea Maritime and Ocean University, Busan 49112, Korea

**요 약 :** 본 연구는 화재진압 및 피난활동을 지원하는 딥러닝 기반의 알고리즘 개발에 관한 기초 연구로 선박 화재 시 연기감지기가 작동하기 전에 검출된 연기 데이터를 분석 및 활용하여 원격지까지 연기가 확산 되기 전에 연기 확산거리를 예측하는 것이 목적이다. 다음과 같은 절차에 따라 제안 알고리즘을 검토하였다. 첫 번째 단계로, 딥러닝 기반 객체 검출 알고리즘인 YOLO(You Only Look Once)모델에 화재시뮬레이션을 통하여 얻은 연기 영상을 적용하여 학습을 진행하였다. 학습된 YOLO모델의 mAP(mean Average Precision)은 98.71%로 측정되었으며, 9 FPS(Frames Per Second)의 처리 속도로 연기를 검출하였다. 두 번째 단계로 YOLO로부터 연기 형상이 추출된 경계 상자의 좌표값을 통해 연기 확산거리를 추정하였으며 이를 시계열 예측 알고리즘인 LSTM(Long Short-Term Memory)에 적용하여 학습을 진행하였다. 그 결과, 화재시뮬레이션으로부터 얻은 Fast 화재의 연기영상에서 경계 상자의 좌표값으로부터 추정된 화재발생~30초까지의 연기 확산거리 데이터를 LSTM 학습모델에 입력하여 31초~90초까지의 연기 확산거리 데이터를 예측하였다. 그리고 추정된 연기 확산거리와 예측한 연기 확산거리의 평균제곱근 오차는 2.74로 나타났다.

**핵심용어 :** 딥러닝, 연기검출, 연기 확산거리 예측, YOLO, LSTM

**Abstract :** This is a basic study on the development of deep learning-based algorithms to detect smoke before the smoke detector operates in the event of a ship fire, analyze and utilize the detected data, and support fire suppression and evacuation activities by predicting the spread of smoke before it spreads to remote areas. Proposed algorithms were reviewed in accordance with the following procedures. As a first step, smoke images obtained through fire simulation were applied to the YOLO (You Only Look Once) model, which is a deep learning-based object detection algorithm. The mean average precision (mAP) of the trained YOLO model was measured to be 98.71%, and smoke was detected at a processing speed of 9 frames per second (FPS). The second step was to estimate the spread of smoke using the coordinates of the boundary box, from which was utilized to extract the smoke geometry from YOLO. This smoke geometry was then applied to the time series prediction algorithm, long short-term memory (LSTM). As a result, smoke spread data obtained from the coordinates of the boundary box between the estimated fire occurrence and 30 s were entered into the LSTM learning model to predict smoke spread data from 31 s to 90 s in the smoke image of a fast fire obtained from fire simulation. The average square root error between the estimated spread of smoke and its predicted value was 2.74.

**Key Words :** Deep learning, Smoke detection, Smoke spread distance prediction, YOLO, LSTM

\* First Author : pooh4762@gmail.com, 051-410-5030

† Corresponding Author : hwangki@kmou.ac.kr, 051-410-4368

※ 이 논문은 “2020년도 해양환경안전학회 공동학술대회(2020. 06. 25-26, p.134)”에서 발표된 “화재시뮬레이션을 활용한 딥러닝 기반 연기 확산거리 예측 모델링”의 수정, 보완된 내용을 일부 포함하고 있음.

## 1. 서론

### 1.1 연구 배경 및 목적

해양안전심판원의 해양사고 통계에 따르면, 최근 3년간 선박의 화재·폭발사고는 매해 증가하는 추세로 2017년 96건 대비 2019년 132건으로 37.5% 증가하였고, 이로 인해 해당 기간 동안 52명의 인명피해가 발생하였다(KMST, 2019)

강제로 만들어진 선박은 화재 시 높은 열전도율로 선박 전체로 화재가 확산될 가능성이 크며, 구조적 특성상 통로를 통해 화재가 빠른 속도로 확산되는 특징을 가진다. 또한 해상에서 화재가 진행되는 환경적 특성상 자체적으로 소화 활동을 해야하며, 화재 진압 과정에서 선내 질은 연기와 고열로 초기 진압실패 시 전소로 인한 침몰로 이어질 수 있는 위험성이 크다(Kim and Hwang, 2016; Hwang et al., 2018). 따라서 선박 화재 시, 초기 화재 감지와 화재 진행 양상 예측을 통한 적절한 대응이 필요하다.

하지만 선내 센서 기반 화재감지기는 화재 발생 후 연기의 농도, 온도상승률 등이 일정 수준에 도달해야 감지기가 작동하여 초기 화재 감지에 어려움이 있다. 이에 반해 영상 기반의 화재 감지는 딥러닝 기술 발전으로 실시간 화재 감지가 가능하며, 화재 위치 및 크기 등과 같은 정보를 파악할 수 있는 장점이 있어 이와 관련된 연구가 진행되고 있다.

Park and Bae(2019)는 선박 기관실에서 화재검출을 위한 합성곱 신경망(CNN, Convolution Neural Network) 이용 딥러닝 알고리즘 중 Tiny-YOLO(You Only Look Once) v2모델을 적용하여 불꽃과 연기검출을 하였다. 검출률과 정확도로 성능을 평가한 결과 불꽃은 0.994, 0.998이고, 연기는 0.978, 0.978로 화재 검출 모델의 우수성을 확인하였다. 또한 Kim and Cho(2020)는 YOLO-v3모델을 적용하여 화염의 발생 여부와 위치 검출이 가능한 화염 감지시스템을 제안하였으며, 화염 탐지 결과 정확도는 0.997, 검출률은 1로 신뢰할 만한 결과를 얻었다. 그러나 기존 문헌들은 화재검출 자체에만 초점이 맞추어져 있어 화재검출 데이터 기반의 연기 발달을 예측한 사례는 찾아보기 어려웠다. 또한 화재시물레이션 툴을 활용하여 선박 화재 시 화재성상을 예측한 사례는 있었지만, 화재시간 300초를 해석하는데 최대 9시간 43분이 소요되어 실시간 화재 상황 예측을 통한 대응은 어려울 것으로 판단되었다(Kim and Hwang, 2017).

이에 본 연구에서는 선내 화재 발생 시 연기감지기 작동 및 공간 전체에 연기가 확산되기 전에 확산거리를 예측하여 실제 화재 상황에서 활용 가능한 알고리즘을 제안하고자 한다. 이를 위해, 딥러닝 기반 객체 검출 알고리즘에 화재시물레이션을 통한 연기 영상을 학습데이터로 적용 및 학습하여 검출된 연기 데이터로부터 연기 확산거리를 추정하였다. 또

한, 딥러닝 기반 시계열 예측 알고리즘에 연기 확산거리 데이터를 적용 및 학습하여 연기 확산거리를 예측하였다.

### 1.2 연구 내용 및 방법

Fig. 1은 기존의 화재 대응 시나리오와 비교하여 본 연구에서 제안한 연기 확산거리 예측 알고리즘 적용 시의 화재 대응 시나리오를 나타낸 것으로, 알고리즘의 작동순서는 다음과 같다.

선박 화재 발생 시 선내 화재감지기가 작동하기 전, 선내 설치된 CCTV 영상을 수집하고 딥러닝 기반의 객체 검출 알고리즘인 YOLO-v3을 이용하여 연기를 검출한다. 그 다음, YOLO-v3로부터 검출된 경계 상자(Bounding box)의 y좌표 값으로부터 연기가 확산된 거리를 추정한다. 마지막으로 시계열 예측 알고리즘인 LSTM(Long Short-Term Memory)에 일정 시간 동안의 추정된 연기 확산거리를 입력값으로 넣고 예측된 일정시간 뒤의 연기 확산거리를 출력값으로 얻는다. 이 결과를 이용하여 화재·피난 안전 담당자는 화재로 인해 실제 연기가 확산되기 전에, 연기 확산이 예측된 장소에서의 화재진압과 피난경로를 승선자에게 제공함으로써 재산·인명 피해를 최소화 할 수 있다.

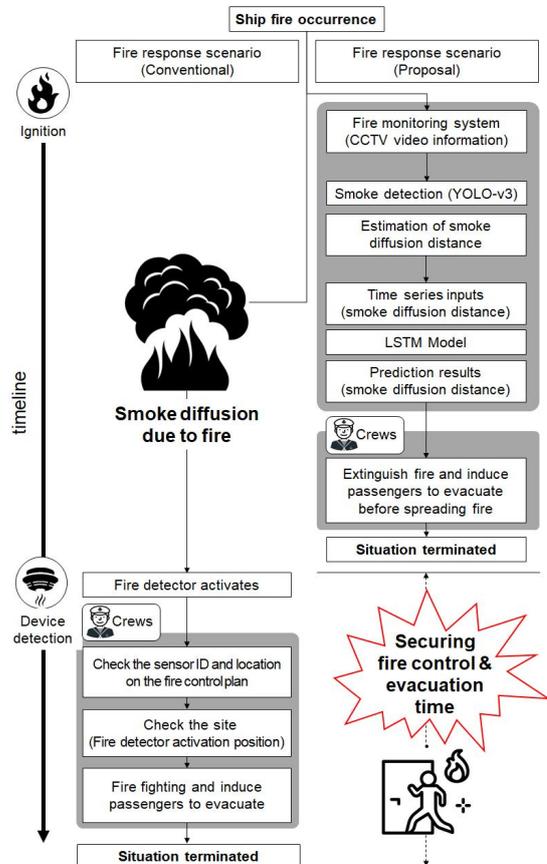


Fig. 1. Fire response scenario applying the proposed algorithm.

## 2. 딥러닝을 이용한 연기 검출

### 2.1 연기 검출을 위한 YOLO-v3 알고리즘

본 연구에서는 연기 발생 유무를 판별하는 것이 아니라, 화재 발생 상황을 전제조건으로 화재 발생 이후부터 연기를 검출하고자 객체 검출 알고리즘인 YOLO를 사용하였다. YOLO는 하나의 합성곱 신경망이 동시에 여러 개의 경계 상자를 예측하고 각 경계 상자에 대하여 분류 확률(Class probability)을 예측한다. YOLO-v3는 Fig. 2와 같이 입력된 이미지에 대하여 S×S의 그리드(grid)로 영역을 구분하고, 한 개의 그리드 셀(grid cell) 당 총 B개의 영역을 지정하고, 각 영역에 대하여 클래스의 확률을 예측한다(Redmon et al., 2016).

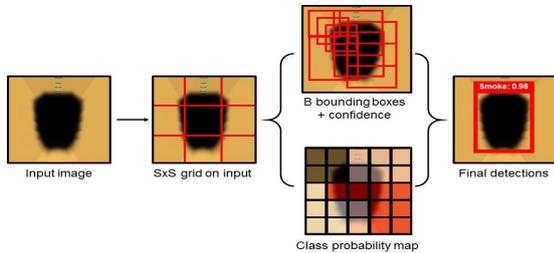


Fig. 2. The YOLO detection system.

각 영역은 식(1)과 같은 신뢰도 점수(Confidence score)와 식(2)와 같은 조건부 클래스 확률(Conditional class probability)를 갖는다. 신뢰도 점수는 해당 영역에 객체가 있을 확률이 얼마나 되는지에 대한 값이며, 조건부 클래스 확률은 해당 상자에 객체가 있는지에 대한 여부를 의미한다.

$$Confidence\ score = Pr(Object) \times IOU_{pred}^{truth} \quad (1)$$

$$Conditional\ Class\ Probability = Pr(Class_i | Object) \quad (2)$$

### 2.2 학습데이터 수집을 위한 화재시뮬레이션

본 연구에서는 경제성 및 안전상의 이유로 선박에 실제 화재를 재현하기에 어려움이 있어, 본 연구에서 제안한 연기 확산거리 예측 모델의 학습 데이터를 확보하기 위하여 화재시뮬레이션을 수행하였다.

화재시뮬레이션은 FDS(Fire Dynamic Simulator, Ver. 6.5.3)를 사용하였고, FDS에 의해 연산된 결과를 3차원으로 시각화하는 툴인 Smokeview를 통해 복도 끝에 CCTV가 위치한다고 가정하여 화재로 인한 연기 영상을 획득하였다(McGrattan et al., 2014). 수치해석 공간과 조건은 Fig. 3과 Table 1에 정리하여 나타내었으며, 요약하면 아래와 같다.

첫째, 선박 거주구역이 주로 선실과 복도로 구성되며, 복도를 통해 피난한다는 점을 고려하여, 복도 모양으로 수치 해석 공간을 구성하였다. 또한 복도의 길이는 주수직구역의 개념을 적용하여 40[m]을 적용하고, SOLAS 규정에 따라 폭은 1[m], 천장의 높이는 2[m]로 적용하였다(SOLAS, 2015a; 2015b).

둘째, 화원의 크기는 가로, 세로 모두 0.5[m]로 설정하고, 선실화재 실험 데이터로부터 얻은 1,680[kW]를 최대 열방출율로 적용하였고, Propane이 연소하는 것으로 가정하였다(Arvidson et al., 2008). 또한 Fig. 4에 표시한 것과 같이 화재 실험값(Experiment)과 화재성장속도(Fire growth model) 별로 설계화재곡선을 생성하고, 화재시뮬레이션에 적용하였다(NFPA, 2005).

셋째, 연기감지기 작동시간을 파악하기 위하여, FSS Code에 따라 Fig. 3에서 보는 것과 같이 연기감지기를 배치하여 감지시간을 파악하였다(IMO, 2000).

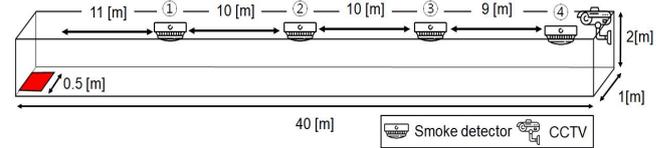


Fig. 3. Fire simulation modeling.

Table 1. Fire simulation input variables

Classification	Input variables
Fire area [m <sup>2</sup> ]	0.5×0.5
Fire growth rate	Slow, Medium, Fast, Ultrafast, Experiment
Max heat release rate [kW]	1,680
Simulation time [s]	0~200

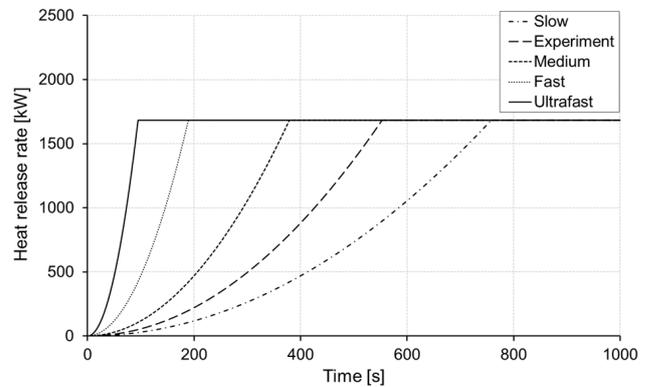


Fig. 4. Fire growth rate.

## 2.3 연기 검출 모델 학습 및 결과

### 2.3.1 데이터 셋 구성

화재성장속도 별 화재시물레이션을 통하여 얻은 가상의 연기 영상으로부터 1,155장의 연기 이미지를 획득한 후 무작위 추출법(Random sampling)으로 825장의 학습이미지와 330장의 테스트 이미지로 나누었다.

### 2.3.2 연기 검출 모델 학습

연기 검출 모델의 학습을 위하여 Window 10, OpenCV 3.2.0, Visual Studio 2015, CUDA 10.0, cuDNN 7.6.5 환경에서 YOLO네트워크를 구현하였다. 학습에 사용된 장비의 사양을 Table 2에 정리하였다.

Table 2. Configuration of experimental equipment

Equipment	Model
Processor	Intel Xeon E5-2650v3 2.3 2133 10C 1st and 2nd CPU
Graphic card	Nvidia Quadro K2200
RAM	128GB (16GB×8)

YOLO-v3모델에서 GPU버전으로 학습을 수행하였으며, 클래스의 종류는 연기 1개로 필터 크기에 관한 식(3)에 의해 18로 적용하였다. 또한 입력 영상의 크기는 416×416으로 설정하였다(Redmon et al., 2016). 그리고 가중치를 갱신할 때 갱신되는 비율을 조절하는 학습률(Learning rate)은 0.001, 누적된 기울기에 의해 현재의 기울기를 보정하는 가속도(Momentum)는 0.9, 과적합을 줄이기 위한 가중치 억제(Weight decay)는 0.0005로 설정하였으며, 학습시간은 약 2시간 소요되었다.

$$Filter = (classes + 5) * 3 \quad (3)$$

### 2.3.3 연기 검출 결과 및 평가

연기 영상의 연기 검출 성능 평가 지표는 YOLO 알고리즘을 활용하여 객체검출 연구를 수행한 선행연구를 참고하여 검출 정확도(mAP: mean Average Precision) 개념을 적용하였다. 연기 영상에서 검출 정확도는 연기가 올바르게 검출된 비율을 의미하여 본 연구에서는 98.71%로 측정되었다. 이는 YOLO 알고리즘을 사용하여 mAP 72.63%의 성능으로 화재를 검출한 선행연구와 비교하여 높은 수치라고 볼 수 있으며 Fig. 5에 검출된 연기 이미지를 나타내었다(Shin and Choi, 2019; Nazilly et al., 2020). 또한 학습된 YOLO-v3모델은 9 FPS(Frames Per Second)의 처리 속도로 연기를 검출하였다. 즉, 프레임 1개당 연기의 크기, 좌표와 같은 정보를 검출하는데 약 0.11초가 소요되었다.

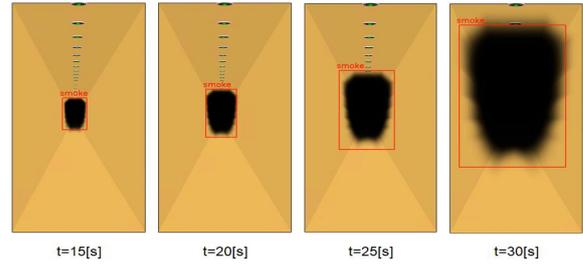


Fig. 5. Smoke detection results by the time.

## 2.4 연기 확산거리 추정

연기 확산거리는 화재가 발생한 지점으로부터 얼마큼 연기가 확산되었는지 나타내는 지표로서 본 논문에서는 YOLO-v3로부터 검출된 연기 경계 상자의 y좌표 값과 그에 상응하는 시물레이션 공간상의 연기감지기 위치 값을 비교하여 y좌표 값을 실제 거리 값으로 변환하였다. 이 과정을 Fig. 6에 나타내었다. 또한 복도의 종방향으로 설치된 연기감지기는 연기의 y축 방향 운동의 영향만 받기 때문에, y좌표만 고려하였다.

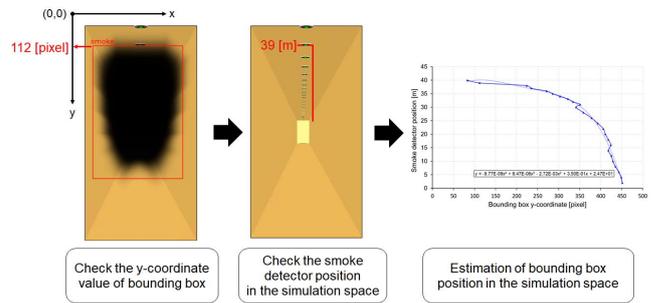


Fig. 6. Estimation of smoke spread distance.

위 과정을 통해 y좌표 값과 연기감지기 위치 값의 상관식을 만들어 이로부터 화재성장속도 별 시간에 따른 연기 확산거리를 구하고 이를 Fig. 7에 나타내었다.

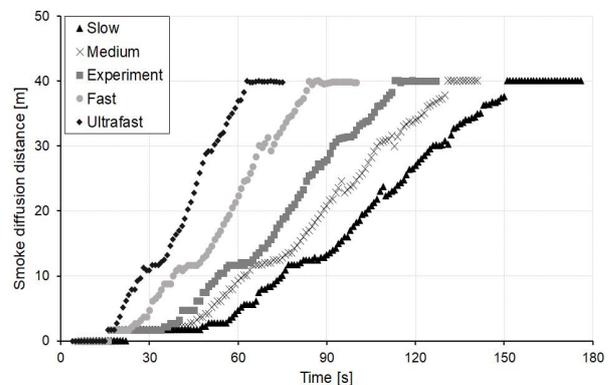


Fig. 7. Smoke diffusion distance by fire growth rate.

### 3. 연기 확산거리 예측

#### 3.1 연기 확산거리 예측을 위한 LSTM 알고리즘

연기 확산거리를 예측하기 위해 시계열 데이터 학습에 적합한 LSTM(Long-Short-Term Memory)를 사용하였다. LSTM은 과거의 데이터와 현재의 데이터의 연관성분석을 통해 미래의 값을 예측하며 LSTM 기반 예측 모델의 구조는 Fig. 8과 같다(Hochreiter and Schmidhuber, 1997; Christopher, 2015). Fig. 8에서  $x$ 는 예측모델의 입력변수이고,  $h$ 는 출력값으로 여기서는 둘 다 연기 확산거리 값이다.

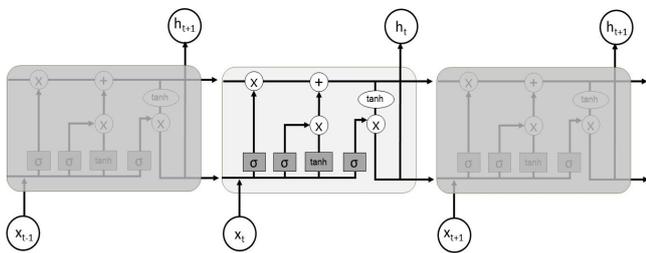


Fig. 8. LSTM based predict model structure.

#### 3.2 연기 확산거리 예측 모델 학습 및 결과

##### 3.2.1 연기 확산거리 예측 모델 학습

본 연구에서 제안한 연기 확산거리 예측 모델을 학습하기 위하여 Python 3.6 기반의 Keras 라이브러리를 사용하였다.

2.3절에서 구한 Slow, Experiment, Medium 그리고 Ultrafast 화재의 연기 확산거리를 학습 데이터로 사용하였고, Fast 화재의 연기 확산거리 데이터를 검증 데이터로 활용하였다.

먼저, 예측 모델의 학습을 위한 데이터 셋을 구성하기 위하여 화재시뮬레이션을 통해 계산된 연기감지기 작동시간을 고려하였다. Table 3에서 볼 수 있듯이, Fast 화재 시 발화 위치에서 가장 인접한 감지기가 40초에 작동하며, 복도 끝에 위치한 연기감지기는 90초에 작동한다. 이 결과로부터 예측 모델에 적용하기 위한 입력 데이터의 시간 범위를 최초 연기감지기가 작동하기 전으로 설정하고, 출력 데이터의 시간 범위는 90초까지만 예측하도록 설정하였다.

Table 3. Activated time for smoke detectors predicted by fire simulation

		①	②	③	④
Smoke detector position [m]		11	21	31	40
Fire growth rate	Fast [s]	40	57	72	90

Table 4에 나타난 것과 같이 시퀀스의 길이를 90초로 고정하고, 연기 확산거리 데이터의 입력시간 범위를 20, 25, 30 초에 대해 출력시간 범위를 각각 70, 65, 60초로 설정하여 학습을 진행하였다. Case3를 예를 들어 설명하면, 학습모델에  $t+1 \sim t+30$ 초의 연기 확산거리를 입력 데이터로 넣으면  $t+30 \sim t+90$ 초의 연기 확산거리를 예측하여 출력하도록 모델링을 하였으며, 이를 Fig. 9에 나타내었다.

Table 4. Sequence modeling

Sequence modeling	Input time period	Output time period	Sequence Length
case1	20	70	90
case2	25	65	90
case3	30	60	90

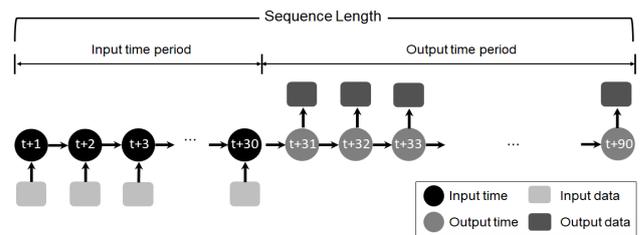


Fig. 9. Sequence modeling.

연기 확산거리 예측 모델의 매개변수(Hyper-parameter)는 Fast화재의 연기영상에서 YOLO-v3로 검출된 경계 상자의  $y$  좌표 값으로부터 추정된 연기확산 거리값(Target)과 예측모델의 연기 확산거리 예측값(Predict)의 차이가 최소화 되도록 조절하였으며 은닉노드(Hidden node), 학습횟수(Epoch), 학습율(Learning rate), 활성화 함수(Activation)는 각각 200, 1500, 0.01, ReLU로 설정하였다.

##### 3.2.2 연기 확산거리 예측 모델 결과 및 평가

Fast화재의 연기영상으로부터 추정된 연기 확산거리 값(Target)과 시퀀스 모델링에 따른 모델 예측값(Predict)을 비교하여 Fig. 10에 나타내었으며, 연기 확산거리 예측 모델을 평가하기 위하여 평균제곱근 오차(RMSE)를 확인하였다. 평균 제곱근 오차는 표준편차를 일반화한 척도로 추정값과 실제 값의 차이가 어느 정도인지를 나타내며 값이 낮을수록 예측 정확도가 높으며 식(4)을 통해 구할 수 있다. 식(4)을 통해, 시퀀스 모델링 별 평균제곱근 오차를 산출하면 case1은 10.36, case2는 11.96 그리고 case3은 2.74로 계산되었다. 즉, 입력시간 범위가 30초이고, 출력시간 범위가 60초인 경우의 예측 정확도가 가장 높음을 알 수 있다.

## 딥러닝 기반의 연기 확산거리 예측을 위한 알고리즘 개발 기초연구

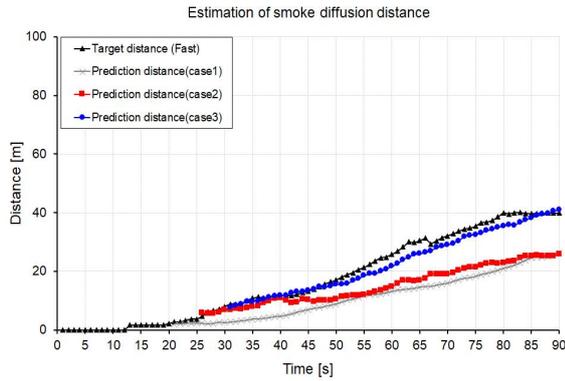


Fig. 10. Comparison of target distance and predicted distance.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (target - predict)^2}{n}} \quad (4)$$

### 4. 결론

본 연구는 딥러닝 기반의 객체 탐지 및 시계열 예측 알고리즘을 통해 선박 화재 시 연기감지기 작동 전에 검출된 연기 데이터를 분석 및 활용하여 연기 확산 전에, 연기 확산거리 예측을 통한 화재진압 및 피난활동 지원 알고리즘 개발을 위한 기초연구로 주요 연구 성과는 다음과 같다.

첫째, 화재시물레이션으로부터 얻은 연기 영상을 YOLO-v3 모델에 적용하여 학습한 결과 검출 정확도 즉, mAP(mean Average Precision)는 98.71%로 나타났으며, 9 FPS(Frames Per Second)의 처리 속도로 연기를 검출하였다. 또한, YOLO-v3 모델로부터 연기 형상이 추출된 경계 박스의 좌표값을 통해 연기확산 거리를 추정하였다.

둘째, 연기 확산거리 데이터의 시계열 예측 모델인 LSTM에 적용하고, 학습을 위하여 입력 데이터의 시간 범위는 Fast 화재 시에, 첫 번째 연기감지기가 작동하는 시간인 40초보다 작은 20, 25, 30초로 설정하였다. 그 결과, 학습 모델에 발화 시작부터 30초까지의 연기 확산거리를 입력값으로 넣었을 때 31초부터 90초까지의 연기 확산거리 예측이 가장 정확했다. 이는 화재시물레이션에 의한 연기 확산거리 값(Target)과 본 연구에서 제안 알고리즘에 의한 예측 연기 확산거리 값(Predict)의 평균제곱근 오차가 2.74로 나타났기 때문이다.

위 결과로부터 본 연구에서 제안한 연기 확산거리 예측 알고리즘 적용 시, 화재 발생 후 연기감지기가 작동하기 전에 검출된 연기데이터로 확산거리 예측이 가능함을 확인하였다.

그러나 본 연구에서 제안된 알고리즘을 실제 화재 상황에 적용하기 위해서는 다음 한계점을 극복해야 한다. 우선, 연기 검출 모델은 화재시물레이션을 통해 얻은 연기영상으로만 학습데이터를 구성하였기에, 추가적인 학습데이터 수집이 필요하다. 또한, 연기 확산거리 예측 모델은 화재성장 모델과 입·출력 데이터 범위를 한정하여 적용하였기에, 데이터 편향 문제가 발생할 수 있으며, 이를 방지하기 위한 학습데이터의 추가 확보와 입·출력 데이터 범위의 다양성 등을 적용할 필요가 있다.

### References

- [1] Arvidson, M., J. Axelsson, and T. Hertzberg(2008) Large-scale fire tests in a passenger Cabin, SP Technical Research Institute of Sweden, Report, pp. 1-100.
- [2] Christopher, O.(2015), Understanding LSTM Networks, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [3] Hochreiter, S. and J. Schmidhuber(1997), Long short-term memory, Neural computation, Vol. 9, No. 8, pp. 1735-1780.
- [4] Hwang, K. I., I. K. Cho., G. H. Yun, and B. Kim(2018), A comparison of the trainees' evacuation characteristics according to the indoor smoke-fullfill during the safety training on ship, Journal of the Korea Society of Marine Environment & Safety, Vol. 24, No. 4, pp. 422-429.
- [5] IMO(2000), International Maritime Organization, MSC.98(73), Adoption of the International Code for Fire Safety System, p. 19.
- [6] Kim, B. and K. I. Hwang(2016), Smoke exhaust performance prediction according to air supply and exhaust conditions for shipboard fires from a human safety point of view, Journal of the Korea Society of Marine Environment & Safety, Vol. 22, No. 7, pp. 782-790.
- [7] Kim, B. and K. I. Hwang(2017), A Study on Crid Size and Generation Method for Fire Simulations for Ship Accommodation Areas, Journal of the Korea Society of Marine Environment & Safety, Vol. 23, No. 7, pp. 791-800.
- [8] Kim, Y. J. and H. C. Cho(2020), Detecting location of fire in video stream environment using deep learning, The transactions of the Korean Institute of Electrical Engineers, Vol. 69, No. 3, pp. 474-479.
- [9] KMST(2019), Korea Maritime Safety Tribunal, Statistics for the marine accidents (in Korean), <https://www.kmst.go.kr/kmst/statistics/annualReport/selectAnnualReportList.do>.

- [10] McGrattan, K., S. Hostikka, R. McDermott, J. Floyd, C. Weinschenk, and K. Overholt(2014), Fire Dynamics Simulator FDS User's Guide, 6th ed., National Institute of Standards and Technology, p. 35.
- [11] Nazilly, M. L., B. Rahmat, and E. Y. Puspaningrum(2020), Implementation of YOLO Algorithm for Fire Detection, Jurnal Informatika dan Sistem Informasi, Vol. 1, No. 1, pp. 81-91.
- [12] NFPA(2005), National Fire Protection Association, Standard for smoke management systems in malls, atria and large area, NFPA 92B.
- [13] Park, K. M. and C. O. Bae(2019), A study on fire detection in ship engine rooms using convolutional neural network, Journal of the Kore Society of Marine Environment & Safety, Vol. 25, No. 4, pp. 476-481.
- [14] Redmon, J., S. Divvala, R. Girshick, and A. Farhadi(2016), You Only Look Once: Unified, Real-Time Object Detection, In: CVPR.
- [15] Shim, S. B. and S. I. Choi(2019), Development on Identification Algorithm of Risk Situation around Construction Vehicle using YOLO-v3, Journal of Korea Academia-Industrial cooperation Society, Vol. 20, No. 7, pp. 622-629.
- [16] SOLAS(2015a), Regulation 3 Definitions, Chapter II-2 Construction-Fire Detection and Fire Extinction.
- [17] SOLAS(2015b), Regulation 13 Means of Escape, Chapter II-2 Construction-Fire Detection and Fire Extinction.

---

Received : 2020. 11. 02.

Revised : 2020. 12. 03. (1st)

: 2021. 01. 07. (2nd)

Accepted : 2021. 02. 25.