



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

이 일 구 교수 지도  
석사학위 청구논문

지능형 감시 카메라를 위한 기계학습  
기반 경량 이상 행위 탐지 메커니즘

2024

성신여자대학교 대학원  
미래융합기술공학과  
이 연 지

지능형 감시 카메라를 위한 기계학습  
기반 경량 이상 행위 탐지 메커니즘

이 일 구 교수 지도

이 논문을 석사학위논문으로 제출함

2023년 11월

성신여자대학교 대학원

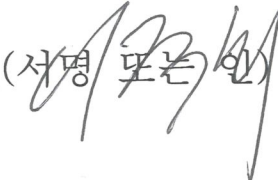
미래융합기술공학과

이 연 지

# 인 준 서

이연지의 석사학위논문으로 인준함

2023년 11월

심사위원장 ..... 이 주 희 ..... (서명 또는 인) 

심사위원 ..... 김 성 민 ..... (서명 또는 인) 

심사위원 ..... 이 일 구 ..... (서명 또는 인) 

성신여자대학교 대학원

## 논문개요

지능형 감시 카메라를 활용한 현장 모니터링의 필요성이 커지면서 기계학습을 접목한 자동화 연구가 중요해지고 있다. 하지만 종래의 연구는 성능과 자원 효율 간의 트레이드 오프(trade-off) 문제를 해결하지 못하고 있다. 따라서 본 연구에서는 지능형 감시 카메라를 위한 기계학습 기반의 경량 학습 모델을 제안한다. 본 논문은 성능이 유지되는 이미지의 해상도를 자동으로 탐색하여 정확도와 복잡도의 최적 조건을 찾는 실시간 경량 화재 탐지 알고리즘을 제안한다. 제안하는 메커니즘은 메모리 사용 효율성을 31.8배 개선한다.

# 목 차

## 논문 개요

I. 서론 .....	1
II. 관련 연구 .....	3
1. CNN(Convolutional Neural Networks) .....	3
1) CNN 개요 .....	3
2) CNN 구성요소 및 동작 방식 .....	4
3) 전이 학습 CNN 모델 .....	8
2. 이상 행위 탐지(Anomaly Detection) .....	10
1) 포인트 이상 행위 .....	11
2) 문맥 이상 행위 .....	12
3) 집합적 이상 행위 .....	12
4) 기계학습 기반의 이상 행위 탐지 .....	12
3. CNN 기반의 이상 행위 탐지 .....	13
III. CNN 기반의 경량 이상 행위 탐지 메커니즘 .....	21
1. 이상 탐지를 위한 이미지 해상도 조정 .....	21
2. 경량 화재 탐지 메커니즘 .....	23

IV. 실험 및 결과 분석 .....	25
1. 데이터셋 .....	25
2. 실험 환경 .....	26
3. 이미지 해상도 조정 .....	28
4. 경량 화재 탐지 메커니즘 .....	31
V. 결론 .....	35

참고문헌

ABSTRACT

ACKNOWLEDGEMENTS

## 표 차 례

TABLE I. Analysis of previous studies on CNN-based anomaly detection .....	17
TABLE II. Dataset distribution table used in the experiment .....	26
TABLE III. Table of module versions used in experiments .....	27
TABLE IV. Image accuracy by resolution (unit: %) .....	29
TABLE V. Memory usage by resolution (unit: BYTES) .....	30
TABLE VI. Probability value by resolution (unit: %) .....	32

## 그림 차례

FIGURE 1. CNN model layer structure diagram[17] .....	5
FIGURE 2. Examples of convolutional networks[17] .....	5
FIGURE 3. Example of convolution filter application .....	6
FIGURE 4. Example of convolution filter application when channel is 3 .....	7
FIGURE 5. Example of applying a convolutional filter with 3 channels and two filters .....	7
FIGURE 6. Example of MaxPooling application .....	8
FIGURE 7. Transfer learning model flowchart .....	9
FIGURE 8. Example of anomaly detection .....	11
FIGURE 9. Flowchart of adjustment to image resolution .....	22
FIGURE 10. Flowchart of model for lightweight fire detection .....	24
FIGURE 11. Example images by fire size .....	26
FIGURE 12. Xception layer used in experiments .....	27
FIGURE 13. Schematic diagram of real-time fire detection mechanism .....	28
FIGURE 14. Detection accuracy graph by resolution (X-axis: resolution, Y-axis: detection accuracy) .....	29
FIGURE 15. Memory usage graph by resolution (X-axis: resolution, Y-axis: memory usage) .....	30
FIGURE 16. Fire probability by resolution (X-axis: resolution,	

Y-axis: probability) .....32  
FIGURE 17. Lightweight fire detection mechanism .....33

## I. 서론

최근 공공 관리 및 보안, 안전 등을 위해 감시 카메라를 활용한 현장 모니터링의 필요성이 커지고 있다[1]. 하지만 감시 카메라를 관독하는 것은 사람의 역할이며 사람은 다수의 카메라를 동시에 관독하기 때문에 효율과 정확도 측면에서 한계가 명확하다[1, 2]. 감시 카메라의 중요한 역할은 교통사고, 자연재해, 범죄 행위와 같은 이상 행위를 탐지하는 것이다. 하지만 앞서 언급한 비정상적인 이벤트는 정상적인 상태에 비해 일어나는 빈도가 현저히 낮으므로 카메라를 관독하기 위한 인적 자원의 노동력과 시간이 낭비된다[2, 3]. 이처럼 노동력 및 시간 측면에서 사람이 직접 감시 카메라를 관독하는 것은 비효율적이므로 이를 완화하기 위한 자동화 연구가 요구되고 있다.

이러한 문제를 해결하기 위해 기계학습을 활용한 이상 행위 탐지 연구가 활발하게 진행되고 있다[4-7]. 기계학습의 하위 모델인 딥러닝은 사람의 개입 없이 훈련할 수 있으며, 객체 탐지, 데이터 분류, 자연어 처리 등 다양한 분야에서 수준 높은 결과를 제공하고 있다[4]. 그중에서도 CNN(Convolutional Neural Networks) 모델은 데이터셋에서 특징을 직접 학습하는 특성이 있어 의료분야부터 농업까지 다양한 분야에서 이상 행위 탐지에 활용되고 있다[5, 8]. 종래 연구는 CNN 모델의 정확도 향상을 위하여 데이터셋의 해상도를 최대한으로 끌어올려 초해상도 이미지를 사용하거나 좋은 품질의 이미지를 사용하고 있다[6]. 하지만 감시 카메라를 비롯한 사물인터넷(Internet of Things)은 에너지와 메모리, 비용 등의 자원이 제약되어 있다[9]. 좋은 품질의 데이터셋은 모델의 성능에 긍정적인 영향을 주지만, 감시 카메라를 활용한 실시간 탐지에는 적합하지 않다[7-10].

초고해상도 이미지로 인한 비용 문제를 해결하기 위해 경량 CNN 모델 개발을 위한 연구가 진행되어 왔다[8-11]. 하지만 선행 연구들은 자원과 비용

에만 초점을 맞추고, 정확도 등의 성능이 저하되거나 고려되지 않았기 때문에 성능과 비용 간의 트레이드 오프(trade-off) 문제를 해결하지 못하고 있다. 따라서 자원 문제를 해결하면서 높은 성능을 유지할 수 있는 최적화 연구가 필요하다.

본 논문은 감시 카메라 데이터셋 중 화재 데이터셋에 대하여 성능과 메모리 간의 최적화 구간을 찾는 것을 목표로 한다. 높은 해상도일 때와 유사한 정확도를 갖는 가장 낮은 해상도를 찾고, 보다 비용 효율적인 화재 탐지를 위한 메커니즘을 제안한다. 제안 메커니즘은 카메라의 해상도를 낮춘 상태를 유지하다가 화재 감지 확률이 임계값을 넘기면, 더 높은 해상도로 전환하는 방식이다.

본 논문이 갖는 기여는 다음과 같다.

- 첫째, 데이터셋의 해상도를 조절하여 정확도가 유지되는 가장 낮은 해상도 지점을 확인함으로써 종래 연구의 한계점인 성능과 비용 간의 트레이드 오프 문제를 개선하였다.
- 둘째, 감시 카메라에 국한되지 않고 다양한 연구 및 환경에 적용할 수 있는 범용적인 경량 전처리 메커니즘을 제안하여 경량 CNN 학습이 용이하도록 하였다.
- 셋째, 화재 탐지의 성능을 유지하면서 메모리 소모량을 31.8배 개선한 경량 화재 탐지 메커니즘을 제안하였다.

본 논문의 구성은 다음과 같다. II장에서는 연구에 사용되는 다양한 배경 지식에 관하여 서술하며, 동시에 딥러닝 학습의 성능, 자원 등을 개선하기 위한 연구들을 조사 및 분석하고, III장에서는 경량 학습을 위한 해상도 조정 메커니즘을 소개한 뒤 이를 응용한 CNN 기반의 경량 화재 탐지 메커니즘을 제안한다. IV장에서는 실험 환경과 실험 내용, 그리고 실험의 결과에 대해 분석하며, V장에서는 결론을 맺는다.

## II. 관련 연구

본 장은 연구에 활용되는 배경 기술인 CNN 모델과 이상 행위 탐지 대해 서술하고, 한계점을 분석한다. 이후 이미지를 활용한 이상 행위 탐지 연구에 대해 분석하고 한계점을 파악하여 본 연구에서 해결하고자 하는 문제점을 서술한다.

### 2.1 CNN(Convolutional Neural Networks)

#### 1) CNN 개요

많은 수의 디바이스가 사람들에게 보급됨에 따라 생성되는 데이터의 수가 기하급수적으로 증가하면서 이러한 데이터를 효과적으로 처리하기 위한 다양한 기술들이 등장하였다[12]. 그중 인공지능(Artificial Intelligence, AI)과 빅데이터(big data) 기술은 동적으로 변화하는 데이터 환경에서 생산성과 효율성을 개선하는 수단으로서 산업체 발전에 크게 기여하고 있다[12].

인공지능에는 자율주행, 사물인터넷, 기계학습(Machine Learning) 등 다양한 기술이 포함되어 있다. 그중에서도 기계학습은 다양한 ICT(Information and Communication Technologies) 분야에 접목될 수 있으며 응용의 폭이 넓어 최근 크게 주목받고 있는 기술이다[13]. 지난 수십 년 동안 기계학습은 정교한 학습 알고리즘과 효율적인 전처리에 있어서 끊임없이 발전해 왔으며 이러한 발전에는 딥러닝(Deep Learning)이 포함되어 있다.

인공 신경망(Artificial Neural Network, ANN)은 인공지능 기술 중 딥러닝에 속하는 기술로 여러 개의 숨겨진 레이어(layer)와 숨겨진 뉴런(neuron)

의 수를 세밀하게 변경하고 여러 퍼셉트론을 심층적으로 조정하여 개선이 가능한 모델이다[14]. 신경망은 이미 인간의 능력을 뛰어넘어 초지능적인 성능을 보이고 있다[15]. 하지만 ANN 및 DNN(Deep Neural Network) 모델은 1차원 데이터를 학습하므로 2차원 데이터를 입력하게 되면 1차원으로 변환하는 전처리 과정을 거쳐야 한다. 이 과정에서 2차원 데이터의 중요한 특징인 지역 및 공간적 정보를 잃게 되며, 이러한 문제 해결을 위해서는 2차원 데이터를 학습할 수 있는 새로운 모델이 필요하다.

CNN은 2차원 데이터에 특화된 딥러닝 모델로 이미지 데이터셋의 특징인 지역 및 공간 정보를 그대로 학습할 수 있다. 즉, 픽셀과 인접한 주변 픽셀들이 갖는 연관성을 유지하고 학습한다[16].

## 2) CNN 구성요소 및 동작 방식

CNN은 Fig. 1과 같이 일반적인 딥러닝 모델과 유사한 형태로 입력층, 은닉층, 출력층으로 구성되며 컨볼루션 레이어를 통해 계산된 이미지의 특징을 출력값으로 사용한다. CNN 모델은 다양한 변형 모델이 존재하지만, 기본 구성요소는 비슷하다[16]. 입력과 출력층을 제외한 은닉층은 컨볼루션 레이어(convolution Layer), 풀링 레이어(pooling layer), 완전연결 레이어(fully-connected layer) 세 가지 유형의 레이어로 구성된다.




FIGURE 1. CNN model layer structure diagram[17]

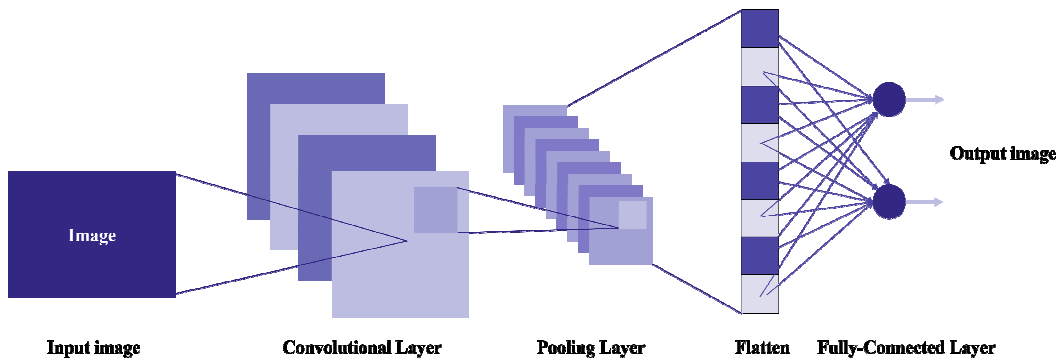


FIGURE 2. Examples of convolutional networks[17]

Fig 1과 Fig. 2는 [17]의 그림을 참고하여 재구성한 그림이다. 컨볼루션 레이어는 입력의 특징과 표현을 학습하는 것을 목표로 두며 Fig. 2와 같이 다양한 특징맵을 계산하는 데 사용되는 여러 컨볼루션 커널로 구성된다. CNN 모델은 반드시  $n \times n$  크기의 2차원 행렬인 컨볼루션 커널을 포함한다[18]. 컨볼루션은 이미지를 커널 단위로 읽고 패턴을 찾아내는 방식으로 동작하며 읽어낸 커널에 컨볼루션 필터를 적용하여 convolved feature를 생성한다. 컨볼루

션 필터를 적용하는 동작 과정에 대한 흐름은 Fig. 3를 통해 상세하게 확인할 수 있다.

우선 이미지를 컨볼루션 필터와 같은 사이즈 단위로 읽어 각 필터의 값을 곱한 다음 각 셀의 값을 더해 결과로 삽입한다. 이때 필터의 개수와 채널의 수에 따라 적용 메커니즘이 다르며 이때 채널은 입력 데이터에 따라 값이 달라진다. 컬러 이미지의 경우 RGB 3개의 값을 각각 입력받으므로 3차원 데이터이며 채널의 값은 3이 된다. 반면 흑백 이미지의 경우 흑과 백 두 가지 값만 갖게 되므로 2차원 데이터이며 채널은 1개로 구성할 수 있다. 채널은 입력 데이터의 채널과 필터의 채널이 반드시 동일해야 한다. 채널 값 변화에 따른 필터 적용 동작의 차이는 Fig 4와 Fig. 5의 예시를 통해 확인할 수 있다.

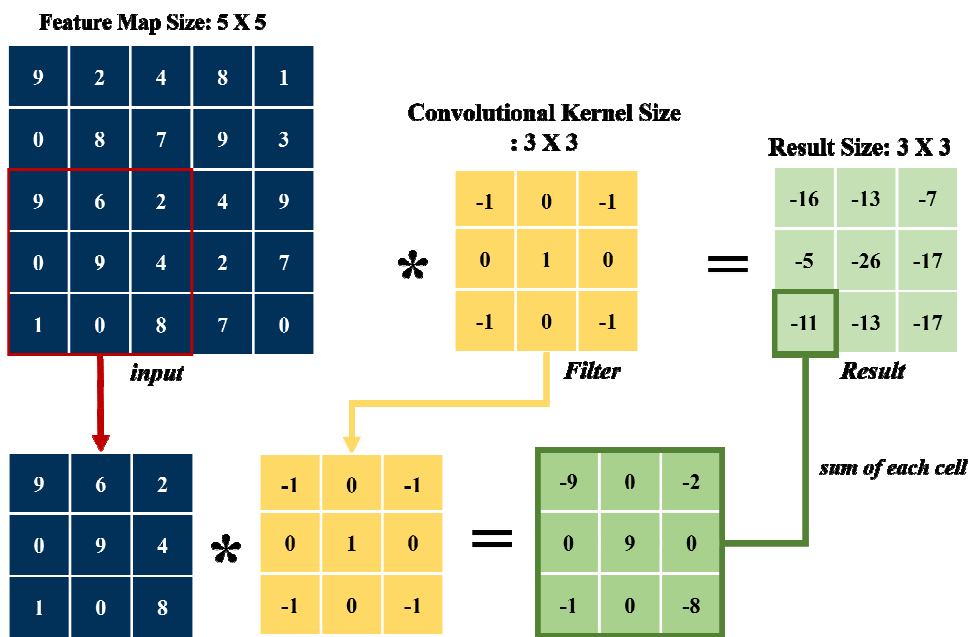


FIGURE 3. Example of convolution filter application

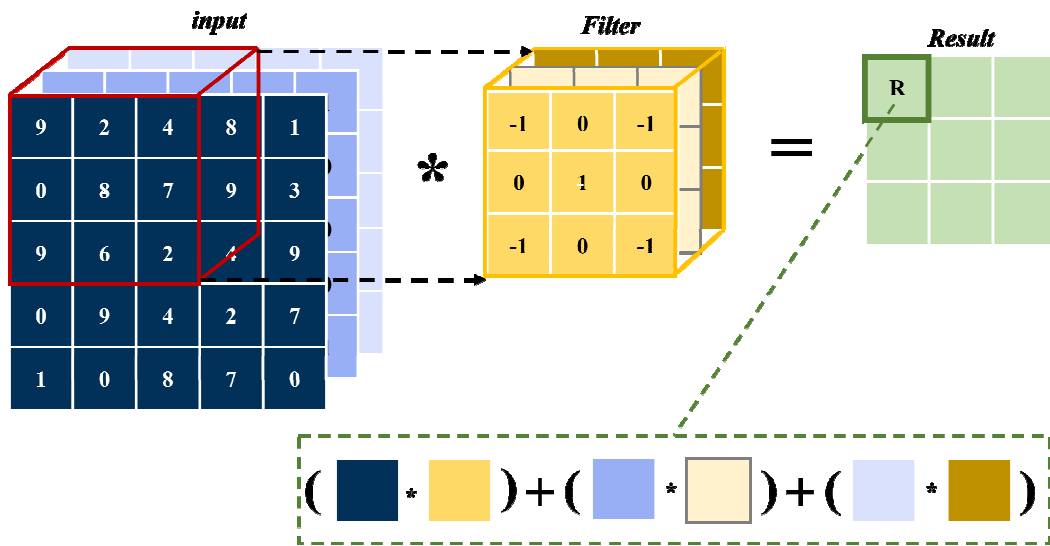


FIGURE 4. Example of convolution filter application when channel is 3

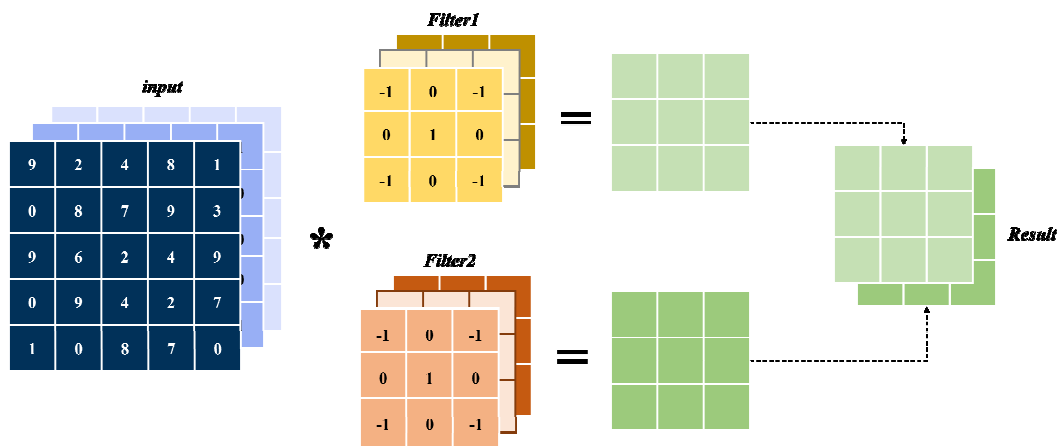


FIGURE 5. Example of applying a convolutional filter with 3 channels and two filters

풀링 레이어는 중요한 정보를 선별하여 학습과 판단을 용이하게 하고 노이즈를 효과적으로 줄이는 것을 목적으로 하는 레이어이다[19]. 컨볼루션 레이어에서 패턴을 쌓아가며 복잡한 패턴을 인식할 때, 풀링 레이어에서는 크기를 줄여가며 추상화한다. 대표적인 풀링 레이어로는 최대 풀링(max pooling)

이 있으며 Fig. 6와 같이 가장 값이 큰 정보를 남기는 방식이다. Fig. 6에서는 풀을 2x2 사이즈로 적용하고 있지만, 별도로 조정이 가능하다.




FIGURE 6. Example of MaxPooling application

완전 연결 레이어는 이름처럼 한 레이어의 모든 뉴런이 다음 레이어의 모든 뉴런과 연결된 레이어를 말하며 Fig. 1와 같이 표현할 수 있다. 이는 2차원 배열인 이미지를 1차원 배열로 다듬는 평탄화 작업을 목적으로 하며 컨볼루션 레이어와 풀링 레이어를 지날 때, 프로세스의 결과를 취합하고 이미지를 정의된 라벨로 분류할 때 사용한다[20].

### 3) 전이 학습 CNN 모델

CNN을 비롯한 딥러닝 모델은 데이터셋의 개수와 퀄리티에 큰 영향을 받아 제한된 크기의 데이터셋으로는 딥러닝 모델의 성능을 기대하기 어렵다[21]. 하지만 실제로 높은 성능을 위해 충분한 데이터셋을 구축하기란 상당히 어려운 일이므로 적은 데이터셋으로도 좋은 성능을 내기 위한 연구가 진행되고 있

다. 전이 학습은 이러한 문제점을 보완할 수 있는 모델로 작은 크기의 훈련 데이터셋을 처리하기 위한 새로운 접근 방식이며 이미 훈련된 모델을 호출해 용도에 맞게 레이어를 미세하게 조정하는 기술이다[22]. 전이 학습의 배경은 사전 훈련된 모델에서 학습한 모델로 새로운 문제를 해결하는 것이며 동작 과정은 Fig. 7와 같다. 사전에 학습된 모델의 일부를 사용하는 만큼 학습 시간을 줄일 수 있어 보다 효율적이다.

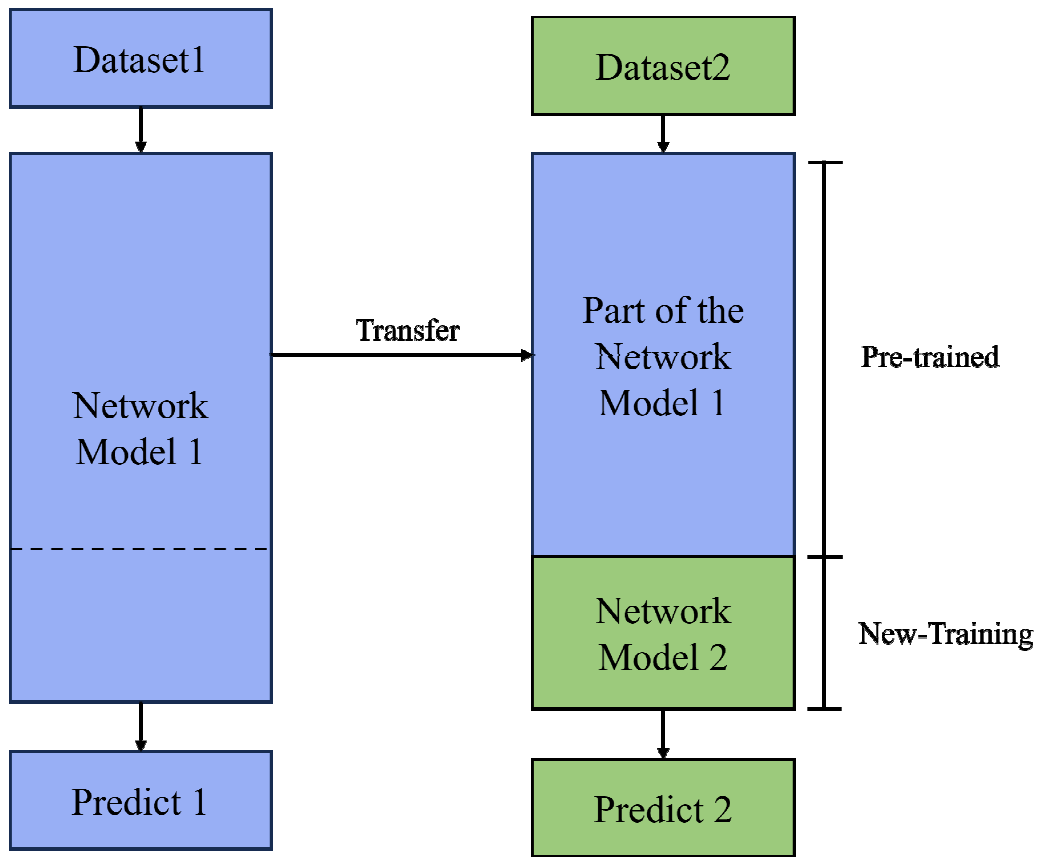



FIGURE 7. Transfer learning model flowchart


전이 학습 CNN 모델은 종류와 수가 다양하며 각각의 모델이 갖는 특징 또한 제각각의 특징이 있다. 이 모델들은 MATLAB과 TensorFlow에서 오픈소스 라이브러리를 제공하고 있어서 쉽게 구현할 수 있다[23, 24].

## 2.2 이상 행위 탐지 (Anomaly Detection)


종래의 이상 행위 탐지 기술들은 정상 동작 패턴과 일치하지 않는 데이터의 입력 패턴을 찾는 방식으로 보안, 경제, 의료 등 다양한 분야에 적용되어 왔다 [25, 26]. 이러한 이상 행위 기술들에서 포인트 이상(point anomaly), 문맥 이상(contextual anomaly), 집합적 이상(collective anomaly) 세 가지 종류로 이상 행위를 나누어 정의하고 있다. Fig. 8은 세 가지 이상 행위의 개념을 보여주는 그림이다. 그림의 x축은 시간을 의미하며 y축은 행위를 수치화 하여 나타낸다. (a)의 포인트 이상행위는 정상적인 행위 수치들 사이에서 단일 이상 행위가 발생하는 것을 의미한다. (b)의 문맥 이상은 정상적인 패턴을 가진 행위의 흐름 속에서 비맥락적인 행위가 발생한 상황을 나타낸 것이다. (c)의 집합적 이상 행위는 연관된 이상 데이터의 집합을 의미하며 연관 있는 두 개 이상의 데이터가 예상한 패턴과 다른 경우를 의미한다.



(a) Point Anomaly



(b) Contextual Anomaly



(c) Collective Anomaly

FIGURE 8. Example of anomaly detection

### 1) 포인트 이상 행위

포인트 이상 행위는 단일 데이터 인스턴스가 다른 나머지 데이터에 대해 이상으로 간주 될 수 있는 경우 해당 인스턴스를 포인트 이상이라고 정의하며 가장 단순한 이상 행위의 형태이다.

## 2) 문맥 이상 행위

특정한 맥락에서 인스턴스가 변칙적이지만 다른 맥락에서는 그렇지 않은 경우에 이를 문맥 이상이라고 한다. 문맥 이상은 연속적인 패턴의 변화를 읽어서 이상치를 감지하며 행위는 맥락을 고려해 예상하지 못한 결과를 탐지한다.

문맥 이상 행위에는 상황적 속성과 행동적 속성의 두 가지 속성이 있다. 상황적 속성은 인스턴스의 컨텍스트를 결정하는 속성이며, 행동적 속성은 인스턴스의 비맥락적인 기능을 정의하는 속성이다. 예를 들어 시간은 전체 시퀀스에서 인스턴스의 위치를 결정하는 시계열 데이터의 상황별 속성이 될 수 있고, 세계 평균 강수량을 설명하는 공간 데이터셋에서 모든 위치에서 발생하는 강수량은 행동 속성이 된다.

## 3) 집합적 이상 행위

연관된 데이터 인스턴스의 집합이 전체 데이터셋에 대해 비정상적인 경우를 집합적 이상이라고 정의하며, 연관 있는 두 개 이상의 데이터 변화를 탐지하여 하나의 데이터 변화에 따른 다른 데이터 변화가 예상했던 패턴이 아닌 비정상 패턴이 될 때까지 탐지를 반복한다.

## 4) 기계학습 기반의 이상 행위 탐지

이상 행위를 탐지하는 방식 중 대표적인 방식은 기계학습이며 정상 라벨과 비정상 라벨을 분류하는 방식이 사용되고 있다. 기계학습은 세 가지 접근 방식이 있는데 지도학습과 준지도학습, 비지도 학습으로 구분한다.

지도학습 기반의 이상 행위 탐지 방식은 정상 라벨과 비정상 라벨 모두에

대해 예측 모델을 구축하고 이 두 가지 모델을 비교하는 방식이다. 지도학습 기반의 이상 행위 탐지는 정확도가 높지만, 이상 행위가 정상적인 행위에 비해 적게 발생하므로, 수집되는 이상 행위가 매우 적어서 데이터의 편향 문제가 있을 수 있다. 대표적인 지도학습 모델로는 서포트 벡터 머신(Support Vector Machine, SVM), K-근접 이웃(K-nearest neighbors)과 딥러닝 모델이 있다.

준지도학습 기반의 이상 행위 탐지 방식은 정상 라벨만 학습하고 정상 행위 범주에 속하지 않는 분류가 어려운 행위는 변칙적인 값이라고 구분한다.

비지도학습 기반의 이상 행위 탐지 방식은 지도학습 적용이 어려운 라벨이 없는 데이터나 라벨링이 난감한 데이터를 학습시키기 쉽고, 라벨링이 되어 있지 않은 데이터에서의 구조와 패턴을 파악할 수 있다. 대표적인 비지도 학습 모델로는 클러스터링(clustering)과 주성분 분석(Principal Component Analysis, PCA), 오토 인코더(autoencoder)가 있다.

본 논문에서는 지도학습 기반의 이상 행위 탐지를 진행하며 그중에서 CNN 모델을 사용한다.

### 2.3 CNN 기반의 이상 행위 탐지

본 절에서는 이미지를 활용한 CNN 기반의 이상 행위 탐지 연구들을 비교 분석하고, 종래 연구들의 한계점과 제안하는 연구의 기여점에 대해 서술한다.

모델의 계산 비용을 낮추기 위한 경량 지능형 CNN 모델을 설계하고 제안한 연구[11]에서는, 아날로그 신호를 디지털 신호로 변환할 때의 전력 소비와 이미지 센서 모듈의 계산 비용 측면의 한계점을 개선하기 위한 연구를 진행했다. ADC(Analog-Digital Converter)의 bit precision을 줄여 전력 소모를

절약하는 방법과 파라미터 수를 줄인 2개의 경량 CNN 모델을 구현하여 검증했다. 논문에서는 MobileNetv2, GhostNet 아키텍처에서 설계한 파이프라인을 검증하여 일반화 능력과 성능을 실험했다. 실험 결과, 제안 모델의 일반화 능력과 전력 소모량이 절감되는 효과를 입증했다는 점에서 기여가 있으나, ADC bit precision이 감소하면 모델의 정확도가 약간 감소하는 부분을 해결하지 못했으며, 데이터셋과 실험이 이미지 데이터에 제한적이라는 한계점이 존재한다.

이미지, 영상처리에서의 전력 소비와 컴퓨터 비전 애플리케이션의 계산 비용 문제를 해결하기 위한 연구[27]에서는, 무선 캡슐 내시경 영상 처리 시 전력 소비 문제를 해결하기 위한 지능형 압축 시스템을 제안했다. 이미지의 중요도를 결정하기 위한 딥러닝 기반 분류 피드백 루프를 제안하였으며, 이미지의 중요도를 판단하여 중요하다고 판단한 이미지는 추가적인 내용을 포함하도록 하여 정보를 향상시키고, 그렇지 않은 이미지는 저화질 이미지로 압축하여 기록한다. 논문에서는 제안하는 모델의 성능 평가를 위해 WCE(Wireless Capsule Endoscopy) 영상에 대한 압축, 분류 실험을 수행하였으며, 지능형 압축 시스템의 gain을 확인, 검증하고 추가로 전송 가능한 이미지의 수를 예측했다. 실험 결과, 영상 품질은 유지하면서 높은 압축률과 높은 분류 정확도를 달성할 수 있음을 검증했다는 데서 기여점을 보였다. 그러나 처리의 시간 복잡도 측면은 고려하지 않았으며, 데이터에서의 병변 여부나 특정 소화기관 등의 한정된 학습과 실험이 진행되어 다른 측면의 학습에서도 동일한 성능을 기대하기 어렵다.

이상 징후를 예측하는 프로세스의 속도를 향상시켜 화재 상황을 탐지하는 연구[28]에서는, 높은 정확도로 패턴 인식을 하는 것 뿐만 아니라, 실시간 실행을 위한 최적화도 중요한 목표로 설정하였다. 연구에서는 Deeplabv3+의 기능과 Open VINO 툴킷을 채택하여 실시간 탐지에 가까운 방법을 제안하고

있으며, 프로세스 가속화 측면의 실험과 평가를 진행했다. 실험 결과 70.46%~93.46% 범위의 추론 프로세스 가속화를 달성하였음을 보였고, FP16 정밀도의 GPU를 사용할 경우 추론 프로세스 속도가 FP32 정밀도에 비해 2배 가량 증가했다. 이 연구는 탐지 모델의 정확도 뿐만 아니라 프로세스 가속화, 속도 등의 시간 복잡도 측면을 고려한다는 점에서 기여점이 있으나, 시간 측면의 영향만을 분석하고 메모리 가용성, 정확도 측면은 고려하지 않았다는 점에서 한계점이 있다.

실제 화재 발생 이미지에 대해 훈련된 CNN 모델을 사용한 연구[29]에서는, 전이 학습을 사용하여 화재를 감지하기 위한 사용자 정의 프레임워크를 제시했다. 화재 시각화 및 위치 파악을 위해 Grad-CAM (Gradient weighted Class Activation Mapping) 방법을 이용하였다. FireDetectionDataset, DeepQuestAI, Saied, Carlo, Bansal의 데이터셋을 융합한 복합 대규모 데이터셋을 생성하여 실험을 진행하였으며 탐지 성능에 대한 평가를 수행했다. 실험 결과, GoogLeNet, VGG16, ResNet50의 탐지 정확도가 각각 88.01%, 64.48%, 92.54%임에 반해 제안하는 EfficientNetB0 모델은 92.68%의 정확도로 개선된 성능을 보였다. 그러나 이 연구는 종래 연구 분석에서 경량화, 계산 비용을 고려했으나 제안 연구에서는 정확도 외의 다른 지표를 추가적으로 분석하지 않았다. 또한 성능이 비슷했던 ResNet50보다 경량화된 모델이므로 EfficientNetB0가 더 좋은 방법이라고 소개하고 있지만, 모델의 경량화 여부를 확인할 수 없다는 한계점이 있다.

[30]은 효율적인 뇌종양 진단을 위해 전처리, 분류, 세분화의 세 단계를 포함하는 자기공명영상(Magnetic Resonance Image, MRI) 기반의 뇌종양 탐지 및 분류 시스템을 개발하였다. 제안하는 방법 중 전처리에서는 뇌 이외의 물질인 안구, 피부, 근육 등을 제거하기 위해 임계화 작업을 진행하며 이미지

데이터 증대를 통해 과적합을 최소화한 95.7%의 정확도를 도출하였다. 해당 연구는 MRI에서 탐지율 극대화를 위해 경량 CNN 아키텍처를 제안하고 있으나, 실질적인 지표로 평가되지 않았기 때문에 실제 개선 여부를 알기 어렵다는 한계점이 있다.

[31]는 원격 심혈관 질환(Cardiovascular Diseases, CVD) 진단 및 관리를 위해 2단계 접근 방식을 적용한 IoT 기반의 심장병 환자 모니터링 및 감지 시스템을 제안하였다. 첫번째 단계에서는 효율적인 데이터 수집을 위해 REL과 DSR을 결합한 라우팅 프로토콜 사용하였고, 두 번째 단계에서는 하이브리드 기반의 심층 특징을 사용하여 ECG이미지를 분류하는 작업을 진행하였다. 제안하는 모델은 경량 모델 제안을 위해 두 번째 단계에서 매개변수를 조정한 입력 레이어를 사용하지만, 실질적인 평가지표로 평가가 이루어지지 않았으므로 실제 경량화에 대한 여부를 명확하게 알기 어렵다는 한계점이 있다.

[32]는 망막 질환 및 기형을 진단하는 데 필수적인 증상인 OCT(Optical Coherence Tomography)를 효율적이고 편리하게 탐지하기 위해 경량 CNN 및 기타 인공지능 모델을 결합하여 노이즈에도 대응이 가능한 딥러닝 모델을 생성하고, 설명 가능한 AI 모델인 LIME(Local Interpretable Model-Agnostic Descriptions) 및 SHAP(SHapley Additive exPlanations)를 활용하여 모델의 동작을 해석할 수 있는 설명을 제공한다. 제안하는 모델은 다양한 데이터셋에서 학습이 되었으며, 편리하고 효율적인 OCT 기반의 진단이 가능해지도록 도왔다는 점에서 기여가 있으나, 사용되는 모델이 많고 각각의 복잡도가 상당히 높기 때문에 경량 모델이라 보기는 어렵다. 뿐만 아니라 레이턴시, 연산 복잡도 등 실질적인 평가지표로 평가가 이루어지지 않았으므로 종래보다 경량화가 되었는지에 대한 여부를 알기 어렵다는 점에서 한계가 있다.

[33]는 뼈의 나이를 평가하기 위해 전이 학습 CNN 모델인 Alexnet 및 GoogLeNet 기반의 새로운 아키텍처를 제시하고자 하였다. 제안하는 방법은 이미지를 서로 다른 네 개의 영역으로 분리하고, 각각을 CNN 모델로 학습한다. 네 가지 CNN 모델은 평균 알고리즘을 기반으로 앙상블 되며 다양한 평가 지표로 성능 평가를 진행하였다. [33]는 뼈 나이를 평가하기 위한 Alexnet 및 GoogLeNet 방법과 새로운 아키텍처를 설계하고 테스트하였다는 점에서 기여가 있으나, 네가지의 모델을 병렬로 동적시키고 앙상블 하게 될 경우 계산 비용 및 레이턴시 등의 효율성이 떨어진다. 즉, [33]에서는 복잡한 알고리즘을 제시하면서 레이턴시와 계산 비용 등의 효율을 고려하지 않았다는 점에서 한계가 있다.

TABLE. I 은 분석한 선행 연구를 요약한 표이다.

TABLE I. Analysis of previous studies on CNN-based anomaly detection

Ref.	Method	Limitation
Wilfred, K. et al. (2023) [11]	<ul style="list-style-type: none"> <li>계산 비용을 낮추기 위한 경량 지능형 CNN 모델 연구</li> <li>ADC의 bit precision을 줄여 전력 소모를 절약하는 방법 제안</li> </ul>	<ul style="list-style-type: none"> <li>데이터셋과 실험이 이미지 데이터에 제한적</li> <li>ADC bit precision이 감소할 때 모델의 accuracy가 감소하는 부분을 해결하지 못함</li> </ul>
Dallel, B. et al. (2021) [27]	<ul style="list-style-type: none"> <li>무선 캡슐 내시경 영상 처리 시 전력 소비 문제를 해결하기 위한 지능형 압축 시스템 연구</li> </ul>	<ul style="list-style-type: none"> <li>시간 복잡도 측면을 고려하지 않음</li> <li>사용한 데이터가 병변, 특정 소화기관 등의 제한적인</li> </ul>

	<ul style="list-style-type: none"> <li>중요도에 따른 딥러닝 기반 분류 피드백 루프 제안</li> </ul>	<p>데이터셋을 이용하여 학습, 실험함</p>
Medina, K. et al. (2023) [28]	<ul style="list-style-type: none"> <li>화재 상황 탐지 모델의 프로세스 속도 가속화</li> <li>실시간 실행을 위한 최적화 연구</li> </ul>	<ul style="list-style-type: none"> <li>다양한 측면의 복잡도를 언급하고 있으나 시간적 복잡도만 고려하고 있고, 메모리 가용성 등의 공간적 복잡도는 고려하지 않음</li> <li>성능 분석을 하지 않음</li> </ul>
Saima, M. et al. (2022) [29]	<ul style="list-style-type: none"> <li>전이 학습을 이용한 화재 감지 프레임워크 제안</li> <li>Grad-CAM을 이용한 화재 시각화 및 위치 파악</li> </ul>	<ul style="list-style-type: none"> <li>경량화, 계산 cost를 언급하고 있으나 실험에서 관련 평가 지표가 고려되지 않음</li> <li>경량 모델이라고 제안한 데에 대한 근거를 확인할 수 없음</li> </ul>
Kamireddy. R. R., Ravindra . D. (2023) [30]	<ul style="list-style-type: none"> <li>전처리, 분류, 세분화의 3단계 MRI 기반의 뇌종양 탐지 및 분류 시스템을 개발</li> <li>뇌 이외의 물질인 안구, 피부, 근육 등을 제거하기 위해 임계화 전처리 진행</li> <li>이미지 데이터 증대를 통해 과적합을 최소화 한 95.7%의 정확도를 도출</li> </ul>	<ul style="list-style-type: none"> <li>경량 CNN 모델을 제안한다고 언급하고 있지만 실질적인 평가지표로 평가가 이루어지지 않음</li> <li>레이턴시, 비용 등이 실제 개선되었는지에 대한 여부가 불분명함</li> </ul>
Tariq. et al. (2023)	<ul style="list-style-type: none"> <li>원격 심혈관 질환(Cardiovascular Diseases, CVD) 진단 및 관리를 위한 2단계 모니터링</li> </ul>	<ul style="list-style-type: none"> <li>경량 CNN 모델을 제안한다고 하며 매개변수를 조정한 레이어를 사용하지만 이를 레이턴시, 복잡도, 비용</li> </ul>

[31]	및 감지 시스템 제안	등의 지표로 평가하지 않음
	<ul style="list-style-type: none"> <li>경량 모델 제안을 위해 두 번째 단계에서 매개변수를 조정된 입력 레이어를 사용</li> </ul>	<ul style="list-style-type: none"> <li>실제 경량화에 대한 여부를 명확하게 알기 어려움</li> </ul>
Mohan. B. et al. (2023)	<ul style="list-style-type: none"> <li>OCT를 효율적이고 편리하게 탐지하기 위해 경량 CNN 및 기타 인공지능 모델을 결합한 딥러닝 모델 생성</li> </ul>	<ul style="list-style-type: none"> <li>사용되는 모델이 많고 각각의 복잡도가 상당히 높기 때문에 실질적인 복잡도가 증가했을 것으로 예상</li> </ul>
[32]	<ul style="list-style-type: none"> <li>설명 가능한 AI 모델인 LIME 및 SHAP를 활용하여 모델의 동작을 해석</li> </ul>	<ul style="list-style-type: none"> <li>실제 평가가 이루어지지 않았기 때문에 종래보다 경량화가 되었는지에 대한 여부가 불분명함</li> </ul>
Maytham N. M. et al. (2023)	<ul style="list-style-type: none"> <li>뼈의 나이를 평가하기 위해 전이 학습 CNN 모델인 Alexnet 및 GoogLeNet 기반의 새로운 아키텍처를 제시</li> </ul>	<ul style="list-style-type: none"> <li>네가지의 모델을 병렬로 동적시키고 앙상블 하게 될 경우 계산 비용 및 레이턴시 등의 효율성이 떨어짐</li> </ul>
[33]	<ul style="list-style-type: none"> <li>이미지를 서로 다른 네 개의 영역으로 분리하고, 각각을 CNN 모델로 학습</li> </ul>	<ul style="list-style-type: none"> <li>복잡한 알고리즘을 제시하면서 레이턴시와 계산 비용 등의 효율을 고려하지 않음</li> </ul>

선행 연구 분석 결과, 이미지 및 영상처리에 관한 종래 연구들 중 최적화가 고려된 연구가 많지 않음을 알 수 있다. 종래 연구들은 성능 측면만을 분석하거나 성능을 제외한 최적화를 분석하는 등 특정 분야에 한정된 성능 분석을 진행하고 있다. 정확도와 복잡도 등을 동시에 고려하는 일부 연구들에서는 정확도가 향상되면 복잡도가 증가하고, 복잡도 측면을 개선하면 정확도가 저하되는 트레이드 오프 관계를 해결하지 못했다. 따라서 본 논문에서는 트레이드

오프 문제를 개선하고 효율적인 화재 탐지를 위해 CNN 모델의 성능을 유지하는 최적의 해상도 지점을 찾고, 이를 사용하여 화재 탐지를 수행하는 경량 이상 행위 탐지 메커니즘을 제안한다.

### III. CNN 기반의 경량 이상 행위 탐지 메커니즘

본 장에서는 지능형 감시 카메라를 위한 경량 학습 모델을 제안한다. 제안 모델은 임계값을 구하기 위한 자동화 메커니즘과 결과물을 활용한 화재 탐지 메커니즘으로 구성된다.

제안하는 경량 CNN 메커니즘은 이미지의 해상도를 낮게 조정하는 것으로 시작하며, 해상도를 낮춰가며 학습과 평가를 반복해 원본 데이터셋과 유사한 정확도를 갖는 해상도 값을 구한다. 이후, 해당 해상도에서의 이상 탐지 확률을 구해 실시간 탐지를 위한 임계값으로 사용한다. 마지막으로 구한 두 가지 임계값을 바탕으로 제안하는 경량 화재 탐지 메커니즘에 대해 서술한다.

#### 3.1 이상 탐지를 위한 이미지 해상도 조정

본 절에서는 제안하는 전처리 과정 및 메커니즘에 대하여 설명하고 구체적인 실행 내용을 단계별로 서술한다. 제안하는 모델은 이미지 종류와 모델에 제한이 없는 범용 메커니즘이다.

이미지 해상도 조정 메커니즘은 경량 이상 탐지 모델에 필요한 임계값을 구하는 과정이며 Fig. 9의 도면과 같이 동작한다. 우선 이미지 데이터셋을 입력하고 이미지의 크기를 원하는 단위로 낮춰가며 조정한다. 이후 생성된 해상도 조정 데이터셋들을 대상으로 각각 학습과 평가를 진행하여 해상도 별 성능을 파악한다. 이후 원본 데이터셋과 성능이 유사하면서 가장 낮은 해상도 값을 구한다. 이때, Fig. 9에서는 이 최소 해상도 값을  $N$ 이라 칭한다. 이후 실시간 탐지에서 사용한 최소 해상도에서의 확률값을 구해 저장

한다. Fig. 9에서는 이 확률값을  $M$ 이라고 칭한다. 이와 같은 일련의 과정은 단순한 과정으로 구성되지만 고화질 데이터와 성능이 유사하면서도 메모리를 최소한으로 사용할 수 있다.

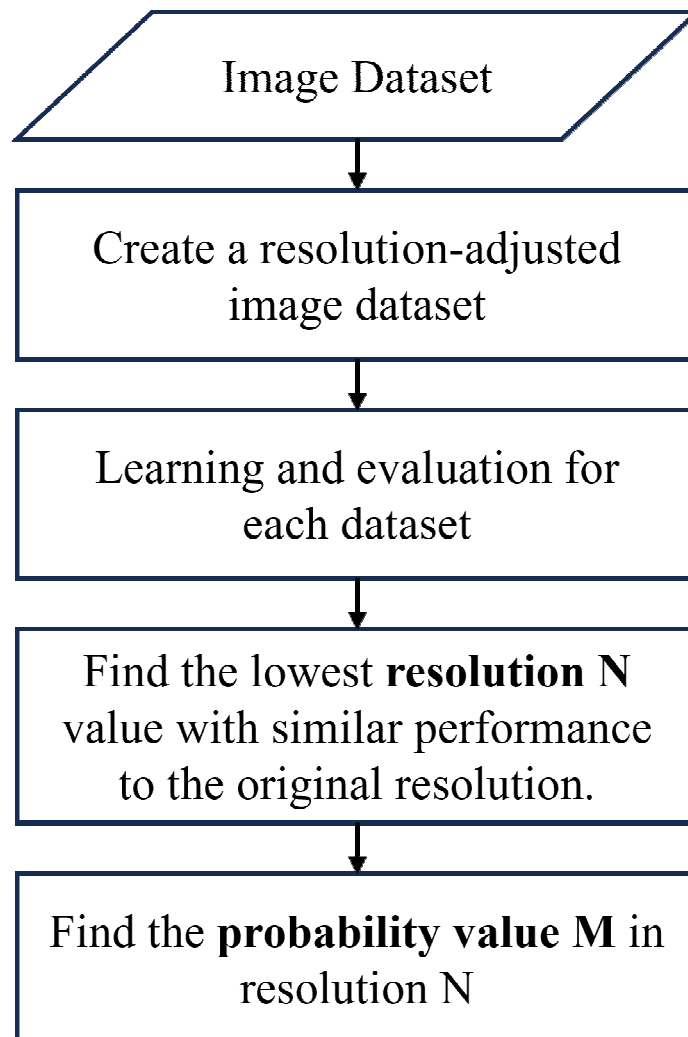


FIGURE 9. Flowchart of adjustment to image resolution

### 3.2 경량 화재 탐지 메커니즘

본 절에서 설명하는 이상 탐지 메커니즘은 앞 절에서 설명한 경량 이상 행위 탐지 메커니즘을 바탕으로 도출한 최소 해상도  $N$ 과 최소 확률  $M$ 을 응용하며, 데이터셋과 서비스 목적에 제한 없이 범용적으로 사용이 가능하다. 본 논문에서는 화재 데이터셋을 선정하였으므로 지능형 감시 카메라를 위한 경량 화재 탐지 메커니즘을 설명한다.

경량 화재 탐지 메커니즘은 사전 해상도 조정 메커니즘을 통해  $N$ 과  $M$ 을 도출한 이후 CNN 기반의 학습 알고리즘을 구축한다. 이에 대한 도면은 Fig. 10와 같고, 여기에서 언급하는  $N$ 은 최소 해상도에 대한 임계값이며,  $M$ 은 실시간 탐지를 위한 화재일 확률값이다.

감시 카메라는 평소에 해상도  $N$ 으로 유지되며, 새로 입력되는 이미지가 화재일 확률이  $M$  이상으로 확인될 경우, 카메라의 해상도를 높게 조정한다. 높은 해상도에서도 화재일 확률이 높게 유지될 경우, 이상 행위로 분류한다.

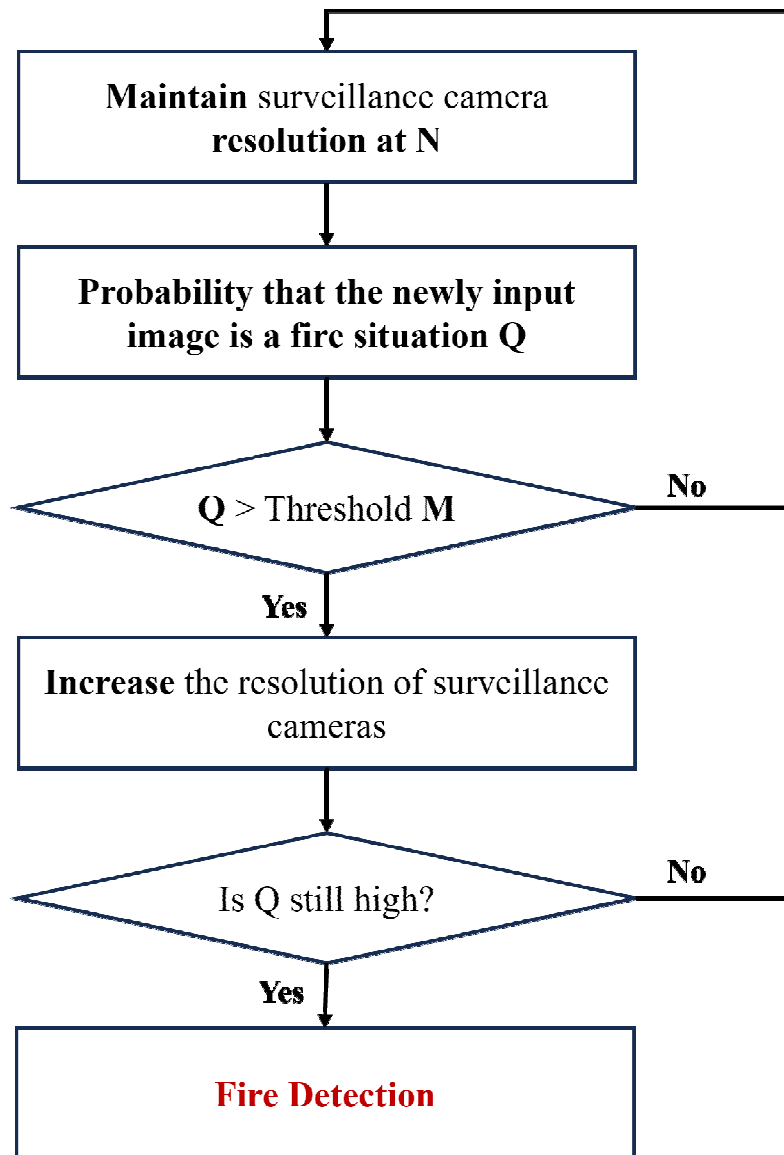


FIGURE 10. Flowchart of model for lightweight fire detection

## IV. 실험 및 결과 분석

본 장에서는 제안하는 모델을 실제로 구현하고 실험하기 위한 실험 환경을 설명하고, 진행한 실험의 내용을 언급한 뒤 실험 결과에 대해 서술한다.

### 4.1 데이터셋

사용하는 데이터셋은 fire-detection dataset [34]으로 화재를 탐지하기 위한 이미지 데이터셋이다. 본 논문에서는 화재를 크기별로 분류하여 각각의 실험 결과를 도출한다. 탐지 대상의 크기가 성능에 영향을 끼치는 데이터셋의 경우 그 제각각 성능이 달라질 것이다. 예를 들어 중앙 이미지 데이터셋의 경우 흑의 크기에 따라 초기와 중기, 말기를 나누어 볼 수 있으며 초기는 말기에 비해 높은 해상도를 요구할 것이고 말기는 비교적 낮은 해상도로도 탐지가 가능할 것이다. 신뢰성이 있는 실험을 위해서는 데이터셋의 크기별 성능을 따로 측정해야 한다. 본 논문은 해당 데이터셋을 일부만 사용하며 화재 이미지를 수기로 검증해 큰 화재, 중간 화재, 작은 화재로 나누었다.

큰 화재는 불이 이미지의 1/2 이상을 차지하는 이미지이고, 중간 화재는 불이 이미지의 1/2보다는 작고 1/4보다는 크게 차지하는 이미지이며, 작은 화재는 불이 이미지의 1/4 이하를 차지하는 이미지이다. 큰 화재와 중간 화재, 작은 화재는 각각 따로 학습하고 대조군이 되는 정상 이미지는 세 가지 모델에 동일하게 적용한다. 이미지의 비율과 실험 별 사용되는 이미지 개수는 TABLE. II와 같다. 이미지에 대한 예시는 Fig. 11에서 확인할 수 있다.

TABLE II. Dataset distribution table used in the experiment

Experiment	Image type	Train	Test	Valid
<b>Large-fire Classification</b>	large-fire image	140	40	20
	normal image	140	40	20
<b>Medium-fire Classification</b>	medium-fire image	140	40	20
	normal image	140	40	20
<b>Small-fire Classification</b>	small-fire image	140	40	20
	normal image	140	40	20



FIGURE 11. Example images by fire size

## 4.2 실험 환경

실험은 Intel(R) Core(TM) i9-10850K CPU와 32.0GB RAM, 930GB Memory, Windows 10 pro 운영체제 환경에서 진행하였다. 사용한 도구는 Anaconda3와 Python 3.10.9 버전이며, 사용한 모듈에 대한 정보는 TABLE. III에서 확인 가능하다.

TABLE III. Table of module versions used in experiments

Module Name	Version
keras	2.10.0
sklearn	1.0.2
numpy	1.23.5
matplotlib	3.5.3
tensorflow	2.10.0
glob	2.69.1
pandas	1.4.2
seaborn	0.11.2

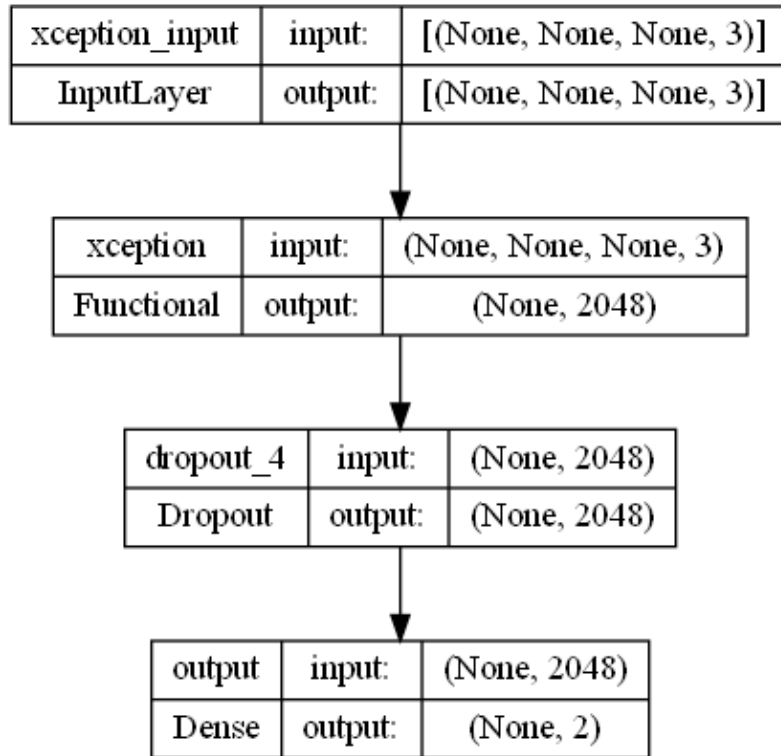


FIGURE 12. Xception layer used in experiments

실험에서는 전이 학습 CNN 모델을 사용한다. 전이 학습 모델은 사전에 학습된 모델을 활용하는 것으로 적은 데이터로도 좋은 성능을 보여줄 수 있기 때문에 적은 이미지 학습 시에 자주 사용되는 모델이며, 각 레이어에 대한 설명은 Fig. 12 에서 확인할 수 있다. 기타 파라미터값은 채널 3, optimizer는 Adam, loss는 binary\_crossentropy를 사용했으며 10 epoch로 학습을 진행하였다.

### 4.3 이미지 해상도 조정

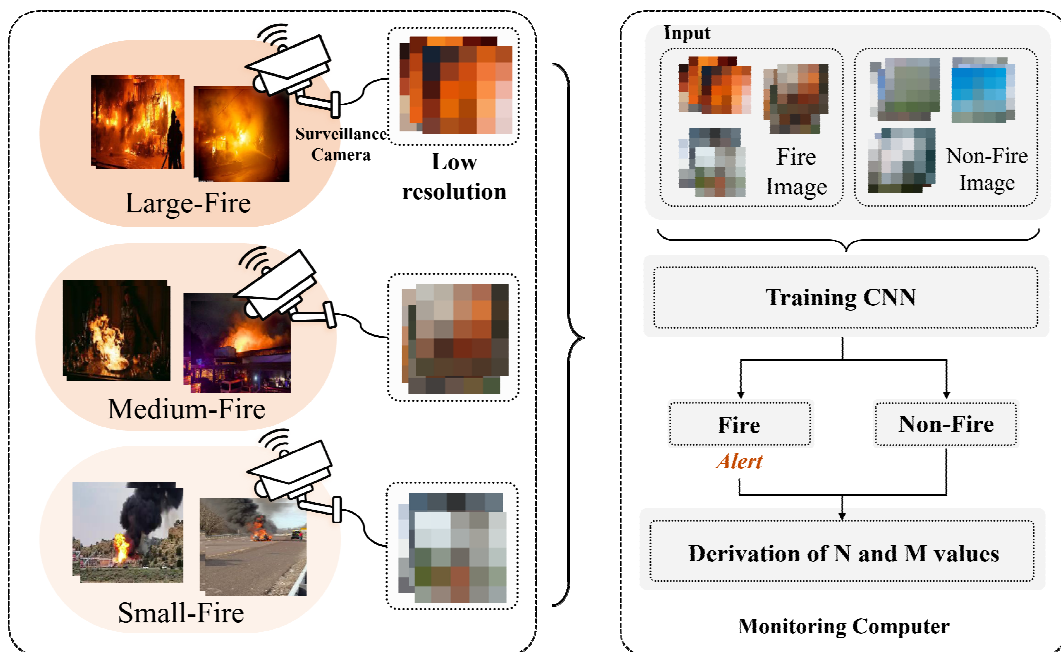


FIGURE 13. Schematic diagram of real-time fire detection mechanism

첫 번째 실험은 성능이 유지되는 이미지 해상도 구간을 확인하기 위해 이미지의 해상도를 100부터 1까지 떨어뜨려 가며 화재와 정상 의 이진 분류를 진

행한 뒤 성능을 측정하였다. 실험에 대한 개략도는 Fig. 13과 같다.

이미지 해상도에 따른 정확도 및 메모리 사용량을 정리한 표는 TABLE. IV와 같다. TABLE. IV를 바탕으로 도식화한 그래프는 Fig. 14이며, 이때, 100부터 20까지는 세 가지 화재 탐지 모델 모두 정확도가 수렴하기 때문에 5부터 20까지만 도식화를 진행하였다.

TABLE IV. Image accuracy by resolution (unit: %)

Resolution	Large	Medium	Small
224	100	99.16	99.16
100	100	97.5	99.16
90	99.16	100	98.33
80	98.33	98.33	99.16
70	100	100	99.16
60	100	99.16	99.16
50	100	100	97.5
40	99.16	96.66	94.99
30	100	97.5	93.33
20	97.5	93.33	95.83
10	98.33	94.99	82.49
5	99.33	96.66	85
1	51.66	50.83	46.66

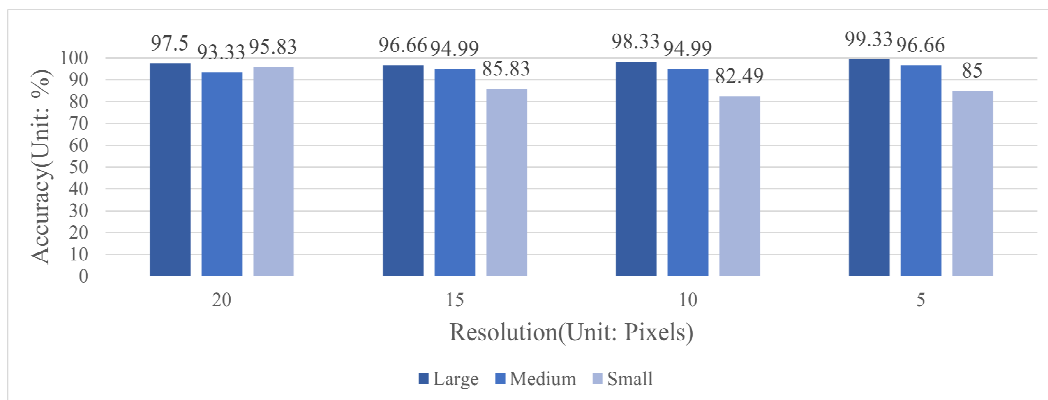


FIGURE 14. Detection accuracy graph by resolution (X-axis: resolution, Y-axis: detection accuracy)

TABLE V. Memory usage by resolution (unit: BYTES)

Resolution	Large	Medium	Small
224	4,624,558	4,648,831	4,422,273
100	7,520,194	7,541,871	7,274,315
90	6,192,685	6,210,347	5,998,943
80	4,983,937	4,996,879	4,836,445
70	3,894,814	3,904,220	3,782,987
60	2,930,476	2,939,180	2,857,270
50	2,096,573	2,102,936	2,050,353
40	1,395,463	1,399,614	1,368,284
30	833,930	835,472	817,709
20	416,853	414,928	405,496
10	146,862	143,976	139,032
5	65,307	62,413	59,550
1	33,780	30,896	28,218

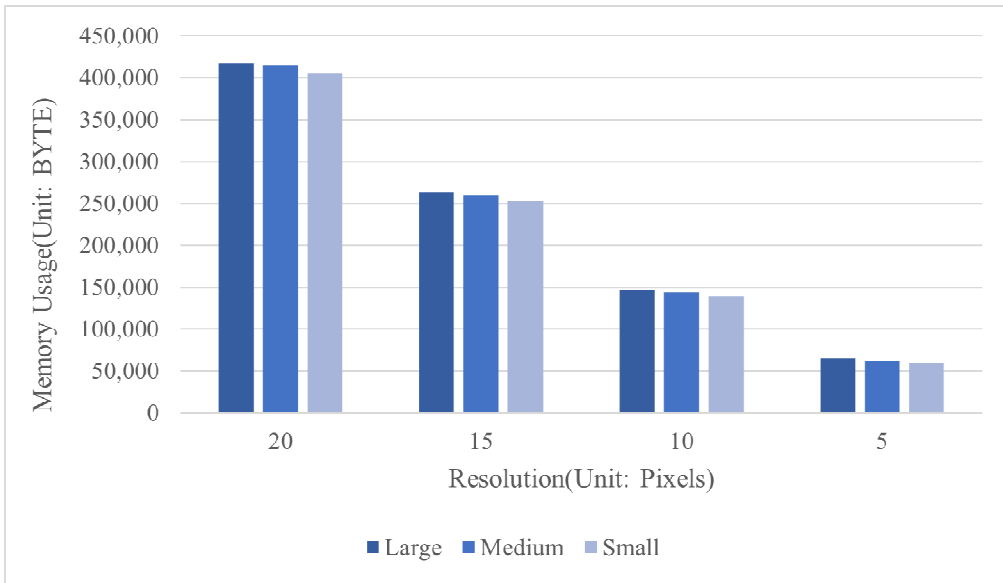


FIGURE 15. Memory usage graph by resolution (X-axis: resolution, Y-axis: memory usage)

큰 화재의 경우 해상도가 5픽셀로 떨어질 때까지 99.3의 정확도를 유지하는 모습을 볼 수 있으며, 중간 화재 역시 5픽셀에서 96.6의 높은 정확도를 유지한다. 하지만 작은 화재의 경우 해상도가 20일 때는 95의 높은 정확도를 유지하나 5일 때는 85의 낮은 성능을 보였다. 따라서 각 데이터셋 별로 성능이 유지되면서 이미지 해상도를 최소한으로 줄일 수 있는 지점은 큰 화재와 중간 화재가 5, 작은 화재는 20인 것을 확인할 수 있다. TABLE. V는 해상도별 사용되는 메모리에 대해 정리한 표이며 Fig. 15는 이를 도식화한 그래프이다. 원본은 224x224 사이즈에 약 460만 Byte이며 큰 화재와 중간 화재의 성능 유지 지점인 5x5는 59,550~65,307 Byte, 작은 화재의 성능 유지 지점인 20은 405,496~416,853 Byte인 것을 알 수 있다. 따라서 큰 화재와 중간 화재는 메모리 사이즈를 최대 70배 줄일 수 있으며 작은 화재는 메모리를 10배 절약할 수 있다.

해당 실험에서 가장 성능이 낮은 것은 작은 화재이다. 하지만 화재는 작은 불에서 큰불로 변지는 것이며 작은 불일 때 탐지하는 것이 가장 중요하다. 따라서 다음 실험에서는 효과적이고 경량화된 화재 탐지 알고리즘을 위해 작은 화재 데이터셋을 활용한 화재 탐지를 진행한다.

### 4.3 경량 화재 탐지 메커니즘

두 번째 실험은 보다 메모리 효율적이고 효과적인 탐지를 위한 경량 화재 탐지 메커니즘에 대해 평가한다. 모델은 특정 임계값을 넘을 경우 해상도를 올리는 방식으로 이루어지며 최대 20까지 조정한다. 제안 모델은 작은 화재일 때 탐지하는 것을 목표로 하므로 앞서 진행한 세 가지 실험 중에서 작은 화재 탐지 실험을 중심으로 진행하였고 모델이 측정하는 화재일 확률값을 측정해

성능을 평가한다. 화재 확률은 화재 라벨에 해당할 확률이며 scikit-learn에서 제공하는 predict\_proba 함수를 사용하였다

TABLE VI. Probability value by resolution (unit: %)

Resolution	Probability
224	99.9875
100	99.3517
90	98.8617
80	99.8051
70	99.0497
60	99.9791
50	99.6371
40	97.044
30	97.3447
20	99.5786
10	74.5524
5	46.9067
1	13.6373

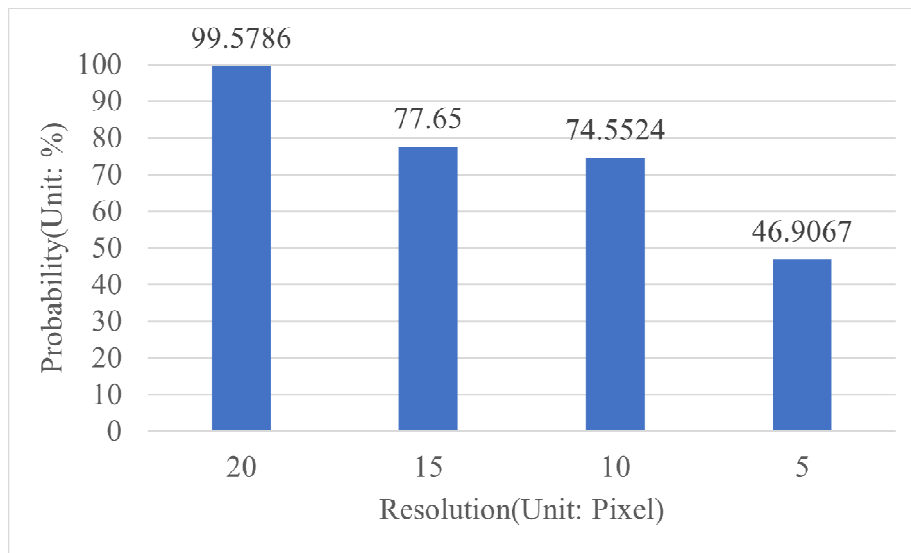


FIGURE 16. Fire probability by resolution (X-axis: resolution, Y-axis: probability)

작은 화재에 대한 해상도별 확률값은 TABLE. VI와 같고 이를 도식화 한 것은 Fig. 16의 그래프와 같다. 해상도가 5일 때 화재 데이터에 대해서는 46%의 확률값을 가졌고 10일 때는 74%, 그리고 20부터는 99%로 수렴하고 있다. 앞서 언급한 최적의 해상도는 5였지만, 5일때의 확률값이 너무 낮기 때문에 최소 해상도는 10으로 지정한다.

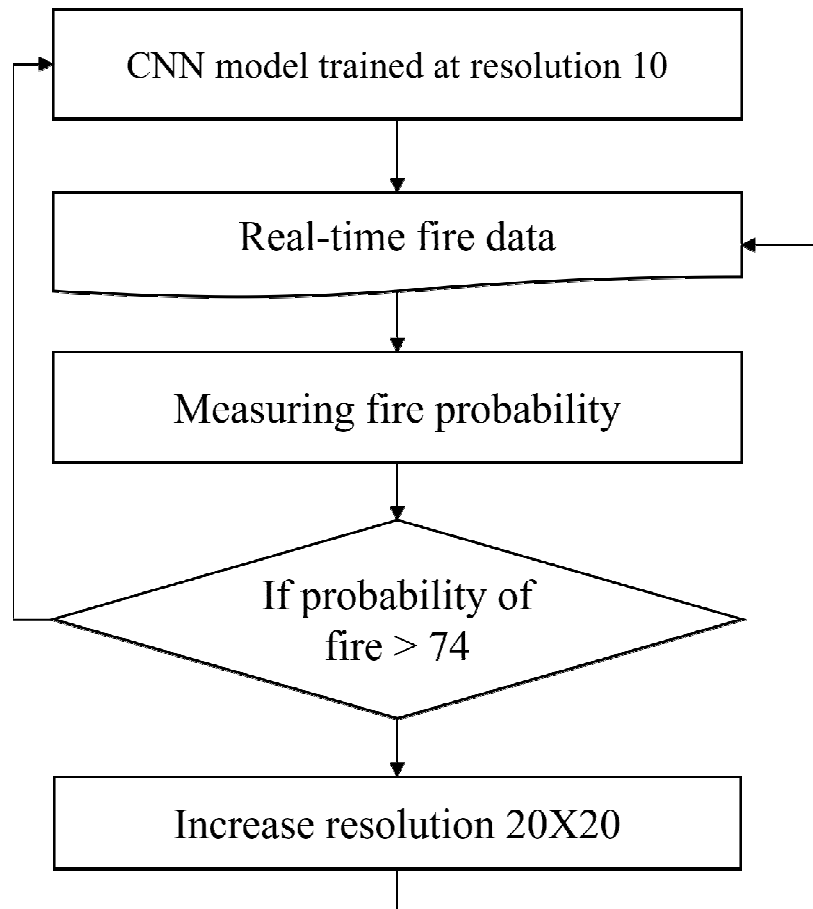


FIGURE 17. Lightweight fire detection mechanism

해당 실험 결과를 반영한 화재 탐지 메커니즘은 Fig. 17과 같다. 감시 카메라는 평상시에 10 정도의 해상도를 유지하며 일반적인 상황에서는 메모리를

절약하다가 실시간으로 입력되는 이미지의 화재 확률이 74% 이상으로 넘어갈 경우 카메라의 해상도를 20 혹은 그 이상으로 올린다. 이 상태에서 화재 감지 확률이 여전히 높은 값을 갖는다면 화재로 판단한다. 이와 같은 메커니즘을 사용하게 될 경우 종래 모델에 비해 메모리 효율적이면서도 오탐율이 낮은 모델을 구축할 수 있다.

## V. 결론

본 논문은 종래 딥러닝 연구의 한계점인 성능과 비용 간의 트레이드 오프 문제를 해결하고자 경량 화재 탐지 모델을 제안하였다. 제안하는 모델은 두 가지 임계값을 필요로 하는데 하나는 최소 정확도이며 다른 하나는 최소 정확도에서의 확률값이다. 본 논문에서는 임계값을 찾기 위해 이미지의 해상도를 조절하여 해상도별 성능 평가를 진행하고, 정확도가 수렴하기 시작하는 지점의 해상도를 확인하였다. 큰 화재 데이터셋과 중간 화재 데이터셋의 경우 해상도가 5일 때 99.3%의 정확도를 보이며 원본에 비해 70배 메모리 효율적임을 입증하였다. 또한 작은 화재 데이터셋은 해상도가 20일 때 95%의 정확도를 보였으며, 이 경우 10배 메모리 효율적임을 보였다. 이후 가장 성능이 낮은 작은 화재 데이터셋을 대상으로 2단계 화재 감지 메커니즘을 제안하였다. 제안하는 메커니즘은 화재로 판단되는 확률 정도에 따라 해상도를 조정하는 모델이며 이는 작은 화재 데이터셋의 확률을 측정하여 임계값으로 사용한다. 결과적으로 제안하는 모델은 화재 탐지 성능을 유지하면서 약 31배 메모리 효율적임을 입증하였다.

하지만 본 연구의 경우 한정된 양의 데이터셋을 활용하였으며 실험 결과 역시 다양한 변수가 반영되었을 가능성이 있어 신뢰할 수 있는 결과를 도출하기 위해서는 방대한 양의 데이터셋으로 진행하는 반복적인 실험이 필요하다. 따라서 향후에는 보다 다양하고 많은 데이터셋을 대상으로 실험을 진행해 볼 예정이다. 반복적인 실험을 통해 신뢰할 수 있는 결과를 도출할 계획이다.

## 참고문헌

- [1] Soheil Vosta, Kin-Choong Yow, "A CNN-RNN Combined Structure for Real-World Violence Detection in Surveillance Cameras", *applied sciences*, 12(3), 2022.
- [2] Waqas Sultani, Chen Chen, Mubarak Shah, "Real-world Anomaly Detection in Surveillance Videos", *the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 6479-6488, 2018.
- [3] Trong-Nguyen Nguyen, Jean Meunier., "Anomaly Detection in Video Sequence With Appearance-Motion Correspondence", *Computer Vision and Pattern Recognition (ICCV)*, 2019.
- [4] Asif Iqbal Khan, S.M.K. Quadri, S.M.K. Quadri, and Junaid Latief Shah, "Deep diagnosis: A real-time apple leaf disease detection system based on deep learning", *Computers and Electronics in Agriculture*, Volume. 198, 2022.
- [5] Amreen Abbas, Sweta Jain, Mahesh Gour, and Swetha Vankudothu, "Tomato plant disease detection using transfer learning with C-GAN synthetic images", *Computers and Electronics in Agriculture*, Volume. 187, 2021.
- [6] Waqas Ahmed, Umair Naeem, Muhammad Haroon Yousaf, and Sergio A. Velastin, "Lightweight CNN and GRU Network for Real-Time Action Recognition", *2022 12th International Conference on Pattern Recognition Systems (ICPRS)*, 2022.
- [7] Daiki Akiyama, and Tomio Goto, "Improving Image Quality Using Noise Removal Based on Learning Method for Surveillance Camera Images", *2022 IEEE 4th Global Conference on Life Sciences and Technologies (LifeTech)*, 2022.

- [8] Feiniu Yuan, Zhengxiao Zhang and Zhijun Fang, "An effective CNN and Transformer complementary network for medical image segmentation" , Pattern Recognition, Elsevier, Volume. 136, 2023.
- [9] Muhammad Rana, Quazi Mamun and Rafiqul Islam, "Lightweight cryptography in IoT networks: A survey" , Future Generation Computer Systems, Elsevier, Volume. 129, Pages 77–89, 2022.
- [10] Muhammad Asif Khan, Ridha Hamila, Aiman Erbad, and Moncef Gabbouj, "Distributed Inference in Resource–Constrained IoT for Real–Time Video Surveillance", IEEE Systems Journal, Volume. 17, pp. 1512 – 1523, 2022.
- [11] Wilfred Kisku, Amandeep Kaur, and Deepak Mishra, "An Intelligent System with Reduced Readout Power and Lightweight CNN for Vision Applications", IEEE Transactions on Circuits and Systems for Video Technology, 2023.
- [12] Huazhou Chen, An Chen, Lili Xu, Hai Xie, Hanli Qiao, Qinyong Lin and Ken Cai, "A deep learning CNN architecture applied in smart near–infrared analysis of water pollution for agricultural irrigation resources" , Agricultural Water Management, Elsevier, Volume. 240, 2020.
- [13] Christian Janiesch, Patrick Zschech and Kai Heinrich, "Machine learning and deep learning" , Electronic Markets, pp. 685–695, 2021.
- [14] Huazhou Chen, Zhenyao Liu, Jie Gu, Wu Ai, Jiangbei Wen, and Ken Cai, "Quantitative analysis of soil nutrition based on FT–NIR spectroscopy integrated with BP neural deep learning" , Analytical Methods, Published by Royal Society of Chemistry, Volume. 10, 2018.
- [15] Amina Adadi, Mohammed Berrada, "Peeking inside the black–box: A survey on explainable artificial intelligence (XAI)", IEEE Access, Volume. 6, pp. 52138–52160, 2018.
- [16] Jiuxiang Gu, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy,

- Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai and Tsuhan Chen, "Recent advances in convolutional neural networks", *Pattern Recognition*, Elsevier, Volume. 77, pp. 354–377, 2018.
- [17] MathWorks, "What Is a Convolutional Neural Network?", last accessed: December 31, 2023, <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.
- [18] Xinyu Lei, Hongguang Pan and Xiangdong Huang, "A Dilated CNN Model for Image Classification", *IEEE Access*, Volume. 7, pp. 124087 – 124095, 2019.
- [19] Shanwen Zhang, Subing Zhang, Chuanlei Zhang, Xianfeng Wang and Yun Shi, "Cucumber leaf disease identification with global pooling dilated convolutional neural network", *Computers and Electronics in Agriculture*, Elsevier, Volume. 162, pp. 422–430, 2019.
- [20] S.H. Shabbeer Basha, Shiv Ram Dubey, Viswanath Pulabaigari and Snehasis Mukherjee, "Impact of fully connected layers on performance of convolutional neural networks for image classification", *Neurocomputing*, Elsevier, Volume. 378, pp. 112–119, 2020.
- [21] Xiaying Wang, Michael Hersche, Batuhan Ṫmekce, Burak Kaya, Michele Magno, and Luca Benini, "An Accurate EEGNet-Based Motor-Imagery Brain-Computer Interface for Low-Power Edge Computing", *2020 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, 2020.
- [22] Zahra Khademi, Farideh Ebrahimi and Hussain Montazery Kordy, "A transfer learning-based CNN and LSTM hybrid deep learning model to classify motor imagery EEG signals", *Computers in Biology and Medicine*, Elsevier, Volume. 143, 2022.
- [23] MathWorks, "Pretrained Deep Neural Networks", last accessed:

- December 31, 2023,  
<https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>.
- [24] TensorFlow, "Transfer learning & fine-tuning", last accessed: December 31, 2023,  
[https://www.tensorflow.org/tutorials/images/transfer\\_learning](https://www.tensorflow.org/tutorials/images/transfer_learning).
- [25] MohammadNoor Injadat, Fadi Salo, Ali Bou Nassif, Aleksander Essex and Abdallah Shami, "Bayesian Optimization with Machine Learning Algorithms Towards Anomaly Detection", 2018 IEEE Global Communications Conference (GLOBECOM), IEEE, 2018.
- [26] Ali Bou Nassif, Manar Abu Talib, Qassim Nasir and Fatima Mohamad Dakalbab, "Machine Learning for Anomaly Detection: A Systematic Review", IEEE Access, Volume. 9, pp. 78658–78700, 2021.
- [27] Dallel Bouyaya, Said Benierbah, and Mohammed Khamadja, "An intelligent compression system for wireless capsule endoscopy images", Biomedical Signal Processing and Control. Volume. 70, 2021.
- [28] Medina Kapo, Adnan Šabanović, Amila Akagic, and Emir Buza, "Early Stage Flame Segmentation with Deep Learning and Intel's OpenVINO Toolkit", 2023 XXIX International Conference on Information, Communication and Automation Technologies (ICAT), 2023.
- [29] Saima Majid, Fayadh Alenezi, Sarfaraz Masood, Musheer Ahmad, Emine Selda Gündüz, and Kemal Polat, "Attention based CNN model for fire detection and localization in real-world images", Expert Systems with Applications, Volume. 189, 2022.
- [30] Kamireddy Rasool Reddy, and Ravindra Dhuli, "A Novel Lightweight CNN Architecture for the Diagnosis of Brain Tumors Using MR Images", diagnostics, Volume. 13, 2023.
- [31] Tariq Sadad, Mejdl Safran, Inayat Khan, Sultan Alfarhood, Razaullah

- Khan, and Imran Ashraf, "Efficient Classification of ECG Images Using a Lightweight CNN with Attention Module and IoT", *sensors*, Volume. 23, 2023.
- [32] Mohan Bhandari, Tej Bahadur Shahi, and Arjun Neupane, "Evaluating Retinal Disease Diagnosis with an Interpretable Lightweight CNN Model Resistant to Adversarial Attacks", *Journal of Imaging*, Volume. 9, 2023.
- [33] Maytham N. Meqdad, Hafiz Tayyab Rauf, and Seifedine Kadry, "Bone Anomaly Detection by Extracting Regions of Interest and Convolutional Neural Networks", *applied system innovation*, Volume. 6, 2023.
- [34] kaggle, "Fire Detection Using Surveillance Camera on Roads", last accessed December 31, 2023, <https://www.kaggle.com/datasets/tharakan684/urecamain/data>.

# ABSTRACT

## Machine Learning based Lightweight Anomaly Detection Mechanism for Intelligent Surveillance Cameras

Yeon-Ji Lee

Department of Future Convergence  
Technology Engineering  
Graduate School of  
Sungshin Wemen's University

The importance of on-site monitoring using intelligent surveillance cameras has grown, leading to an increasing significance of automation research incorporating machine learning. However, conventional studies have struggled to address the trade-off issue between performance and resource efficiency. Therefore, in this study, we propose a machine learning-based lightweight learning model for intelligent surveillance cameras. This paper introduces a real-time lightweight fire detection algorithm that automatically explores the resolution of images to find the optimal conditions for accuracy and complexity. The proposed mechanism improves memory usage efficiency by 31.8 times.

## ACKNOWLEDGEMENTS

어느새 2년간의 석사과정을 마치고 학위 논문을 제출하게 되었습니다. 지난 2년 동안 도움을 주신 많은 분께 이 글을 통해 감사의 인사를 드립니다. 특히 학위 논문을 지도해주시고, 부족한 부분을 세심하게 지도해주신 이일구 교수님과 학위 논문의 공저자로 함께한 박나은 학생에게 한 번 더 감사 인사를 전합니다.