

화재방호 설비 설계 자동화를 위한 선행연구 및 기술 분석*

Literature Review and Current Trends of Automated Design for Fire Protection Facilities

홍성협** · 최두찬*** · 이광호****
Sung-Hyup Hong · Doo Chan Choi · Kwang Ho Lee

Abstract

This paper presents the recent research developments identified through a review of literature on the application of artificial intelligence in developing automated designs of fire protection facilities. The literature review covered research related to image recognition and applicable neural networks. Firstly, it was found that convolutional neural network (CNN) may be applied to the development of automating the design of fire protection facilities. It requires a high level of object detection accuracy necessitating the classification of each object making up the image. Secondly, to ensure accurate object detection and building information, the data need to be pulled from architectural drawings. Thirdly, by applying image recognition and classification, this can be done by extracting wall and surface information using dimension lines and pixels. All combined, the current review of literature strongly indicates that it is possible to develop automated designs for fire protection utilizing artificial intelligence.

Keywords: Fire Protection System(화재 방호 설비), Artificial Intelligence(인공지능), Object Detection(객체 탐지), CNN(합성곱 신경망)

1. 서론

최근 초고층 건축물의 수요 증가 및 건축물의 기능, 목적의 다양화에 따라 다양한 화재 위험성 또한 증가하고 있다. 이에 따라 건축물에 따른 화재방호 설비 또한 요구되는 상황이다(국민안전처, 2016). 많은 화재안전기술의 발전에도 불구하고 그림 1과 같이 화재사고 발생 건수는 증가와 감소를 반복하는 형태를 보이고 있으나, 인명피해의 경우 지속적으로 증가하는 양상을 보이고 있다(소방청, 2019). Sprinkler Successes in One-And

Two-Family Homes and Apartment (NFPA Fire Analysis and Research Division, 2014)에 따르면 건물 내에 자동 소화설비 적용을 했을 경우, 인명 피해 및 금전적인 피해 감소가 가능한 것으로 나타났다.

이처럼 초고층 건물을 비롯한 여러 용도의 건물들에게 있어 화재소방 설비의 중요성은 점차 증가되는 추세이다. 소방시설 설계는 타 분야와 달리 화재 예방 및 인명피해 방지를 위하여 국가차원에서의 설계 기준을 구체적으로 제시하고 있으며, 명확한 설치 기준이 존재하기 때문에 이를 바탕으로 컴퓨터 공학

* 이 연구는 2020년 산업통상자원부 및 산업기술평가관리원(KEIT)의 우수기업부설연구소 육성사업(ATC+) 연구비 지원에 의한 연구(20009710)결과의 일부를 정리한 것임.

** 고려대학교 건축학과 박사과정(주저자: hsh6639@korea.ac.kr)

*** 한방유비스 대표이사(dc4111@kfubis.com)

**** 고려대학교 건축학과 부교수(교신저자: kwhlee@korea.ac.kr)

(Received: October 7, 2020 / Revised: December 1, 2020 / Accepted: December 1, 2020)

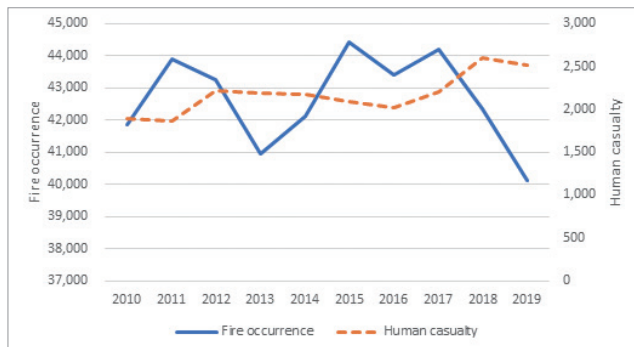


Fig. 1. Number of Fire Occurrence and Human Casualty (Fire Department, 2019)

(특히, 인공지능)과의 연계가 쉽다고 볼 수 있다. 즉, 설계자의 주관적인 판단이 제한됨으로 인공지능 학습을 통한 체계화·최적화가 가능하다.

이에 따라 본 연구에서는 이미지 처리 분야에서 광범위하게 이용되고 있는 합성곱 신경망(CNN)을 기반으로 건축 도면(CAD) 자동인식, 소방 시설 관련 법규학습을 통한 화재방호 설비 설계 자동화 지능형 모델 개발 방향성을 제시하고자 한다.

2. 선행연구

본 연구에서는 보다 정확한 이미지 학습, 감지, 분류를 위하여 다양한 분야에서의 선행연구를 살펴보았으며, 이는 다음과 같다. Zhuo et al.(2018)는 수많은 Train Data를 통한 성능 향상을 위하여 UAV이미지로 전송하여 이미지 주석을 생산하고 CRF모델을 사용하여 이미지를 예측 하는 방법을 제시하였다. 또한 생성된 이미지 주석은 정확한 의미 전달 및 이미지 경계를 보존하였다. 그 결과 수작업을 통한 분류와 비슷한 수준의 정확도를 달성하였다. Zhang et al.(2020)는 이미지 분할은 컴퓨터 비전 및 이미지 이해를 위한 중요한 작업으로 정확도를 향상시키는 핵심이라고 주장하였다. 또한 2차 다항식을 기반으로 한 새로운 FCM 알고리즘을 제안 및 편차 값 계산을 통한 인접지점의 예측 정확도를 향상시켰다. 그 결과 이미지 분할에서 가장 약한 부분인 가장자리 영역의 정확도가 향상하였다. 이는 안정적인 이미지 분할이 이미지 세부 정보를 유지할 수 있음을 나타낸다. Pérez-Borrero et al.(2020)는 Instance segmentation의 새로운 방법론을 제시하였다. 분류 및 필터링 알고리즘을 기반으로 기존에 잘 알려진 Mask R-CNN 네트워크의 Bounding Box를 제거하고 단순화시키기 위하여 새로운 분류 그룹을 추가 필터링하였다. 그 결과 동일한 이미지를 인식하는 것에 있어 기존의 방법보다 추론 시간이 감소하는 것을 확인하였다.

이미지 인식 정확도 향상과 관련된 선행연구는 다음과 같다. Ganesh et al.(2019)는 RGB 및 HSV 영상으로 구성된 다중 입력 데이터를 사용하여 Mask R-CNN를 통한 이미지 검출 및 픽셀 분할에 Deep Orange라는 접근법을 제시하였다. 또한 알고리즘의 성능은 RGB와 RGB+를 사용하여 비교하였으며, 이미지에서 검출된 픽셀의 Mask를 획득하였다. 그 결과 HSV를 통한 RGB를 사용할 때의 정밀도는 0.8947에서 0.9753으로 증가한 것으로 나타났다. Sharma et al.(2019)는 이미지 데이터를 사용하여 CNN모델을 훈련시킴으로써 새로운 이미지를 예측하고자 하였다. F-CNN 모델과 S-CNN 비교를 통한결과를 바탕으로 이전에 본 적이 없는 독립적인 이미지를 훈련시켜 약 98.6%의 정확도를 가지게 되었다. Lui et al.(2020)는 CNN을 기반으로 이미지 영역 감지를 통한 영상 분할 기법을 제시하였다. 이를 위해 1차로 명확한 기본 이미지를 우선 감지하였으며, 이외의 불규칙한 이미지는 필터를 통해 2차 진행하였다. 그 결과 불규칙적인 이미지의 분할 예측 정확도 또한 90% 이상을 나타냈다. Tian et al.(2020)는 U-Net을 사용하여 Mask Scoring R-CNN을 개선하여 Instance Segmentation의 감지 및 분류 세분화를 제안하였다. 정확도를 높이기 위하여 200개의 배경 샘플 이미지를 통하여 Train Data를 구성하였다. 그 결과 mIoU는 91.55%를 나타냈다. Ruiz-Santaquiteria et al.(2020)는 딥러닝 방식을 사용하여 각 Class에 속하는 픽셀을 정확하게 예측하기 위하여 Instance Segmentation과 Semantic Segmentation을 비교하였으며 두 개의 방식에서 겹침이 발생하였을 경우 분리하는 방식을 제시하였다.

3. 이미지 객체 감지 분류

이미지 객체 탐지에 관한 연구들은 크게 세 가지로 분류할 수 있으며, 이는 그림 2와 같다. 첫째, OD(Objectness Detection)는 탐지를 목표로 하며, 사물 단위로 픽셀을 분리한다. 사물의 위치를 바탕으로 Bounding Box를 생성한다. 일반적으로 OD는 수많은 가설을 바탕으로 이루어진다. 둘째, SOD(Salient Object Detection)는 탐지의 또 다른 하나로써 시각적인 요소에 강한 것이 특징이다. 즉, 배경으로부터 사물을 분리하고 위치를 추적하여 객체를 탐지한다. 마지막으로 COD(Category Specific Object Detection)는 주어진 이미지에서 미리 학습한 객체를 탐지하는 것을 목표로 한다. 즉, Region Proposal을 이용하여 객체를 인식 및 분류하는 것이다(Han et al., 2018).



Fig. 2. Research Directions in Object Detection (Han et al., 2018)

4. 이미지 산출을 위한 신경망 기술 분석

4.1 CNN(Convolutional neural network)

합성곱 신경망(CNN)은 대뇌의 시각 피질 연구로부터 시작되었으며, 1980년대부터 이미지 인식 분야에 사용되기 시작하였다. 전 세계적으로 최근 몇 년 동안 컴퓨터 성능의 향상은 많은 양의 훈련 데이터, 심층 신경망을 훈련시키기 위한 기술로 이어졌다. 그 결과 CNN은 복잡한 이미지 처리, 예측 및 분류는 사람을 능가하는 정확도를 달성하였다. 또한 CNN은 이미지 검색, 자율주행, 영상 분류 시스템 등에 큰 역할을 하고 있으며, 최근에는 시각 분야뿐만 아니라 음성인식 및 자연어 처리와 같은 다양한 분야에 적용되고 있다(Aurelien, 2018).

CNN의 중요한 요소로는 크게 합성곱층(Convolutional Layer)과 Feature Map이 있으며, 각각의 은닉층에서의 특성 조합을 통한 계층적 구조는 이미지인식에 큰 도움을 주며, CNN의 구조는 그림 3과 같다. CNN을 통한 이미지 인식에서는 일반적인 심층 신경망을 사용하지 않는다. 심층 신경망이란 완전 연결층을 의미하며, 작은 이미지에서는 문제없이 작동하지만 큰 이미지의 경우 아주 많은 파라미터가 생성되는 문제점이 발생하



Fig. 3. Architecture of CNN (Aurelien, 2018)

기 때문이다. CNN은 층을 부분적으로 연결하여 이러한 문제점이 발생하지 않도록 한다. 또한, 과대적합의 위험을 줄이기 위하여 풀링을 진행한다. 풀링층이란 파라미터의 수를 줄이기 위하여 이미지의 축소판을 만드는 것이다. 이러한 작업을 통하여 이미지가 약간 이동해도 신경망에서 받는 영향을 줄일 수 있다. 풀링층은 2가지로 나눌 수 있으며, 이는 최대 풀링층(Max Pooling Layer)과 평균 풀링층(Average Pooling Layer)이다 (Aurelien, 2018).

4.2 CNN의 종류

4.2.1 LeNet

LeNet은 1998년에 제안되었으며, 손 글씨 숫자를 인식하는 네트워크이다. 합성곱 계층과 풀링 계층을 반복하며 결과를 출력하기 전의 계층에서 완전 연결층을 가지고 있다. LeNet은 현재의 CNN과 비교하였을 때 몇 가지 차이점을 나타낸다. 기존의 LeNet의 경우 Sigmoid 함수를 주로 사용하였으나 현재의 CNN은 대부분 ReLU 함수를 사용한다. 또한 LeNet는 서브 샘플링을 통하여 데이터 크기를 줄인 반면 현재 CNN은 최대 풀링을 사용한다(Aurelien, 2018). LeNet구조는 다음 그림 4와 같다.

4.2.2 AlexNet

AlexNet은 합성곱 계층과 풀링 계층을 반복하며 결과를 출력하기 전의 계층에서 완전 연결층을 가지고 있으며, 이는 LeNet과 크게 다르지 않다. 그러나 활성화 함수로 ReLU 함수를 사용하고 있으며, LRN이라는 국소적 정규화 및 드롭아웃을 사용한다(Aurelien, 2018). AlexNet구조는 다음 그림 5와 같다.

4.2.3 YOLO(You Only Look Once)

YOLO의 가장 큰 특징은 기존 Object Detection에서 사용하




Fig. 4. Architecture of LeNet (Lecun et al., 1998)




Fig. 5. Architecture of AlexNet (Smirnov et al., 2014)

던 방식에서 Region Proposal을 사용하지 않았다는 것이다. 즉, 일반적인 CNN이 이미지를 일정한 규칙으로 나누어 여러 개의 이미지를 감지하는 방식이라면, YOLO는 단 하나의 신경망에서 작업을 진행하기 때문에 한 번의 이미지 인식을 통해서 객체를 감지하는 것이다. 이러한 방식이 가능한 이유는 다음 그림 6을 통해 쉽게 이해가 가능하다. 우선 인식하고자 하는 이미지를 Grid영역으로 나누어 준다. 각각의 Grid 영역에 물체가 위치한 부분에 Bounding Box를 생성하여 예측을 진행하며, 해당 Box의 정확도를 나타내는 Confidence를 계산한다. YOLO는 이미지에서 빠르게 객체를 감지하는 모델이라고 할 수 있으나 Grid 단위로 예측을 진행하기 때문에 해당 Bounding Box에 동일한 물체가 존재하는 경우 객체를 정확하게 인식하지 못한다는 단점이 있다(Redmon et al., 2016).

4.2.4 Semantic Segmentation

Semantic Segmentation은 분류(Classification), 감지(Localization/Detection), 분할(Segmentation)로 나눌 수 있다. 분류란 Input값에 대하여 하나의 레이블을 예측하는 작업이다. 감지란 물체 또는 이미지의 레이블을 예측하면서 Bounding Box 및 위치 정보를 제공한다. Bounding Box는 인식하고자 하는 이미지 감지 정확도에 큰 영향을 미친다. 또한 이미지 형태가 단순하고 주변 이미지와의 차이가 클수록 정확도는 상승하게 된다. 분할이란 모든 픽셀의 레이블을 예측하는 것을 말한다(Chen et al., 2018; 최경훈·하중은, 2020). 최근에는 자율주행 시스템 뿐만 아니라 이미지들을 분할하여 MRI와 같은 의료 영상분석, 질병초기진단, 농작물 상태파악 등 다양한 분야에서 응용되어 사용되고 있다(최승혁 외, 2020). Semantic Image Segmentation의 경우에는 같은 Class의 객체를 구별하지 못한다는 점을 주의해야 한다. 즉, 3명의 사람이 존재하는 이미지의 경우 사람으로

분류는 가능하지만 해당 픽셀자체가 분류할 때 사람1, 사람2, 사람3으로 분류하지 못한다. 이는 단순히 픽셀을 통한 분류에서 어떤 Class에 속하는지에만 관심이 있다는 것이다. AlexNet, VGG와 같은 이미지 분류에 자주 사용되는 심층 신경망들은 Semantic Segmentation에 적합하다고 볼 수 없다. 신경망이 진행됨에 따라 이미지 Class의 위치 정보를 점점 소실하게 되며, 이를 방지하기 위해 풀링, 패딩작업을 진행하여도 메모리 등의 문제가 발생하기 때문이다(Chen et al., 2018)

4.2.5 Instance Segmentation

최근 Image Segmentation이 높은 정확도를 보여줌에 따라 Instance Segmentation에 대한 관심이 증가하고 있다. Instance Segmentation이란 Semantic Segmentation과 달리 객체 분류가 가능하다는 장점이 있다. 또한 Mask R-CNN은 Instance Segmentation 및 Extra Mask Head와 같은 기능을 추가한 객체 감지 알고리즘이다. 이를 통하여 각각의 객체는 픽셀에서 Segmentation을 형성 및 배경으로부터 분리가 가능하다(Andrew, 2009).

4.2.6 FCN(Fully Convolutional Network for Semantic Segmentation)

FCN이란 Semantic Segmentation의 대표적인 모델이라고 할 수 있다. 일반적인 CNN의 경우 Class 예측은 가능하지만 이미지의 위치는 감지하지 못한다. 따라서 기존의 일반적인 CNN모델을 그대로 적용하여 사용할 수 없다. 특징맵들의 크기를 기존의 이미지 크기로 복원시켜 주기 위해 Upsampling작업을 진행하여야 한다. 다시 말해 이미지 크기가 복원됨에 따라 각 Class에 해당하는 이미지 위치 정보 감지가 가능해진다. 그러나 FCN-32s를 진행할 경우 해당 이미지의 디테일이 떨어지는 문제점이 발생한다. 이러한 문제점을 추가로 해결하기 위한 방법으로 Skip Combining이라는 기법을 적용시켜야 한다. Skip Combining이란 그림 7과 같으며, 이전 단계의 Convolution과 특징맵을 참고하여 Upsampling을 진행하는 방식이다. 즉, 이전단계의 특징맵

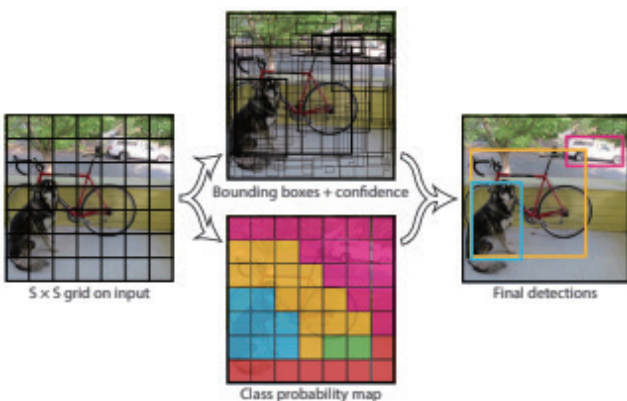


Fig. 6. YOLO Detection System (Redmon et al., 2016)




Fig. 7. FCN Skip Combining (Shelhamer et al., 2017)

을 반복적으로 적용하여 Upsampling을 진행하는 방식이며, 해당 방법을 FCN-8s라고 부르기도 한다(Shelhamer et al., 2017).

4.2.7 ResNet

ResNet은 보다 깊은 층을 가지고 있으며, 이는 성능 향상에 중요한 부분이다. 그러나 Deep Learning의 경우 학습에서 층이 지나치게 깊으면 오히려 성능이 떨어져 정확한 학습이 어려운 문제점이 있다. ResNet은 3.7 FCN에서 언급한 Skip Combining을 사용하여 이러한 문제점을 해결하였다(Aurelien, 2018).

5. 건축도면 객체감지 및 정보추출

본 연구에서는 CNN을 적용하여 건축도면 인식을 진행하고자 하였으며, 정확한 객체감지 및 정보 추출을 위하여 다음과 같은 요소를 고려하였다.

도면정리의 경우 도면 인식에 불필요한 요소를 제거하는 작업을 의미하며, 이를 통해 객체의 인식 정확도를 향상시키고자 한다. 불필요한 요소란 축선, 대지선, 벽체중심선, 치수선 등과 같이 도면 인식을 방해하는 요소이다.

객체인식의 경우 각 객체의 특성 파악을 위하여 필터를 사용하고자 한다. 필터란 합성곱층에서 가중치 파라미터들을 의미하며, 학습단계에서 적절한 필터를 찾는 것이 중요하다. 또한 인식하고자 하는 건축도면에 필터를 적용하여 필터와 유사한 이미지 영역을 강조하는 Feature Map을 다음 Layer로 전달하는 작업이 필요하다.

6. 결론

건축물의 대형화, 기능의 다양화가 증가함에 따라 화재 위험 요소 또한 증가하고 있다. 따라서 본 연구는 화재방호 설비 설계 자동화를 위한 지능형 모델 개발의 기초 연구로 이미지 산출을 위한 선행연구 및 적용 가능한 기계학습 이론에 대하여 조사하였다. 이를 바탕으로 화재방호 설비 설계를 위한 도면 인식 및 설계 모델 개발 가능성을 확인하고자 하였으며, 추후 이미지 분류 및 자동 설계 신경망 모델을 제시하고자 한다.

첫째, 기계학습 기법 중 이미지를 학습, 감지, 분류가 가능한 CNN에 대한 분석을 하였다. CNN을 사용하는 경우 이미지 위치 소실 및 객체탐지 식별이 어려운 문제점이 발생하였으나 이미지 인식, 분류, 분할에 있어 효과적인 성능을 보이는 FCN과 Semantic Segmentation를 통해 해결하고자 한다.

둘째, 정확한 건축도면 객체 감지 및 정보 추출을 위하여 기

존의 도면들을 사용하여 1차적인 학습이 필요함에 따라, CNN을 사용하여 건축 도면을 구성하는 객체를 학습 후 정확도를 확인하여야 한다.

셋째, 이미지 인식 및 분류 기술의 적용 가능성을 바탕으로 건축도면 객체감지 및 정보추출을 진행하고자 한다. 화재 방호 설비 설계는 각 건축물의 용도 및 면적에 따라 다소 차이가 있어 정확한 면적 정보 추출이 필요하다. 이를 위해 치수선 및 픽셀을 이용한 벽면과 면적 정보 추출을 진행하고자 한다.

본 연구에서는 인공지능 선행 연구 분석, 관련 알고리즘 자료 조사 및 이미지 인식을 통한 화재방호 설비 설계 자동화 신경망 모델 개발 가능성을 판단하였으며, 추후 인공지능을 통한 화재방호 자동 설계 모델 개발이 가능할 것으로 판단된다.

참고문헌

1. 국민안전처(2016), 「지능형 초고층 화재방호시스템 개발」.
2. 소방청(2019), 「화재통계연보」.
3. 최경훈·하중은(2020), “주행 이미지 왜곡에 따른 Semantic Segmentation 변화”, 「제어로봇시스템학회 국내학술대회 논문집」, 26(7): 330-331.
4. 최승혁·하현수·김태진·정구익·이상준(2020), “Semantic Segmentation 기술 동향에 대한 연구”, 「한국정보과학회 2020 한국컴퓨터종합학술대회 논문집」, 1550-1552.
5. Andrew, A. M. (2009), *A Missing Link in Cybernetics: Logic and Continuity*, IFSR International Series in Systems Science and Systems Engineering, Springer.
6. Aurelien, G. (2018), *Hands-on Machine Learning with Scikit-learn & Tensorflow*, Hanbit Media.
7. Chen, L. C., Y. Zhu, G. Papandreou, F. Schroff and H. Adam (2018), “Encoder-decoder with atrous separable convolution for semantic image segmentation”, *ECCV 2018 papers*, 801-818.
8. Ganesh, P., K. Volle, T. F. Burks and S. S. Mehta (2019), “Deep orange: mask R-CNN based orange detection and segmentation”, *IFAC-Papers Online*, 52(30): 70-75.
9. Han, J., D. Zhang, G. Cheng, N. Liu and D. Xu (2018), “Advanced deep-learning techniques for salient and category-specific object detection”, *IEEE Signal Processing Magazine*, 35(1): 84-100.
10. Ruiz-Santaquiteria, J., G. Bueno, O. Deniz, N. Vallez and G. Cristobal (2020), “Semantic versus instance segmentation in microscopic algae detection”, *Engineering Applications of Artificial Intelligence*, 87: 103271.
11. Lecun, Y., L. Bottou, Y. Bengio and P. Haffner (1998), “Gradient-based learning applied to document recognition”,

- Institute of Electrical and Electronics Engineers*, 86(11): 2278-2324.
12. Lui, D., Z. Jia, M. Jin, Q. Liu, Z. Liao, J. Zhong, H. Ye and G. Chen (2020), "Cardiac magnetic resonance image segmentation based on convolutional neural network", *Computer Methods and Programs in Biomedicine*, 197: 105755.
 13. NFPA Fire Analysis and Research Division (2014), "Sprinkler successes in one-and two-family homes and apartment".
 14. Pérez-Borrero, I., D. Marín-Santos, M. E. Gegúndez-Arias and E. Cortés-Ancos (2020), "A fast and accurate deep learning method for strawberry instance segmentation", *Computers and Electronics in Agriculture*, 178: 105736.
 15. Redmon, J., S. Divvala, R. Girshick and A. Farhadi (2016), "You only look once: unified, real-time object detection", *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779-788.
 16. Sharma, P., Y. P. S. Berwal and W. Ghai (2019), "Performance analysis of deep learning CNN models for disease detection in plants using image segmentation", *Information Processing in Agriculture*, Available online 18 November 2019.
 17. Shelhamer, E., J. Long and T. Darrell (2017), "Fully convolutional networks for semantic segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4): 640-651.
 18. Smirnov, E. A., D. M. Timoshenko and S. N. Andrianov (2014), "Comparison of regularization methods for imageNet classification with deep convolutional neural networks", *AASRI Procedia*, 6: 89-94.
 19. Tian, Y., G. Yang, Z. Wang, E. Li and Z. Liang (2020), "Instance segmentation of apple flowers using the improved mask R-CNN model", *Biosystems Engineering*, 193: 264-278.
 20. Zhuo, X., F. Fraundorfer, F. Kurz and P. Reinartz (2018), "Building detection and segmentation using a CNN with automatically generated training data", *In 2018 IEEE International Geoscience and Remote Sensing Symposium - IGARS*.
 21. Zhang, X., Y. Ning, X. Li and C. Zhang (2020), "Anti-noise FCM image segmentation method based on quadratic polynomial", *Signal Processing*, 178: 107767.