

Pest Control System using Deep Learning Image Classification Method

Backsan Moon*, Daewon Kim**

Abstract

In this paper, we propose a layer structure of a pest image classifier model using CNN (Convolutional Neural Network) and background removal image processing algorithm for improving classification accuracy in order to build a smart monitoring system for pine wilt pest control. In this study, we have constructed and trained a CNN classifier model by collecting image data of pine wilt pest mediators, and experimented to verify the classification accuracy of the model and the effect of the proposed classification algorithm. Experimental results showed that the proposed method successfully detected and preprocessed the region of the object accurately for all the test images, resulting in showing classification accuracy of about 98.91%. This study shows that the layer structure of the proposed CNN classifier model classified the targeted pest image effectively in various environments. In the field test using the Smart Trap for capturing the pine wilt pest mediators, the proposed classification algorithm is effective in the real environment, showing a classification accuracy of 88.25%, which is improved by about 8.12% according to whether the image cropping preprocessing is performed. Ultimately, we will proceed with procedures to apply the techniques and verify the functionality to field tests on various sites.

▶ Keyword: Image Processing, Convolutional Neural Network, Background Subtraction, Classification

I. Introduction

소나무 재선충이란 약 0.6mm에서 1mm 크기 내외로 아주 작은 크기의 실과 같은 형태를 가진 선충으로서 소나무류의 수중에 기생하여 이를 고사시키는 해충이다. 소나무 재선충은 스스로 나무와 나무 사이를 이동할 순 없지만 다른 나무 사이를 옮겨 다니는 솔수염하늘소나 북방수염하늘소의 몸 안에 기생하다가 이들 매개충이 소나무의 새순을 갉아먹을 때 생긴 상처 부위를 통해 대상 나무에 침입하여 빠른 속도로 증식하며 체관 및 수관을 막아 고사시킨다. 이렇게 감염된 소나무는 3주 이내에 잎이 변색하며 이후 1개월 정도 경과한 후 잎 전체가 갈색으로 변하며 나무 전체가 고사되기 시작한다.

감염된 나무는 당해 연도에 약 80%, 이듬해에 약 20% 정도의 비율로 굉장히 빠른 속도로 고사하며 한 번 감염되면 치료가 불가능하기 때문에 피해가 더욱 커진다. 국내에서 소나무 재

선충병은 전국적으로 2013년에 약 48만 그루, 2014년도에 약 218만 그루, 2015년도에 약 174만 그루, 2016년도에 약 137만 그루, 2017년도에 약 99만 그루로서 최근 5년간 평균 135만 그루의 소나무류에 피해를 입혀왔다. 따라서 산림청이나 전국의 시·도 지자체는 이에 대해 경각심을 갖고 인근 지역으로의 전이를 방지하기 위해 이미 감염된 소나무를 벌채하거나 파쇄하고 예방약을 주사하여 추가 감염을 예방하는 등 피해를 최소화하기 위해 노력하고 있다[1].

최근에는 소나무재선충을 매개하는 곤충인 북방수염하늘소나 솔수염하늘소를 포획하기 위해 그림 1과 같이 곤충 페로몬을 이용한 유인 트랩을 사용하기 시작하였다. 페로몬을 이용한 유인 트랩은 곤충이 다른 개체와의 상호작용을 위해 특정 화학 물질을 분비해 서로를 부르는 것에 착안하여 제작된 것으로서

• First Author: Backsan Moon, Corresponding Author: Daewon Kim

*Backsan Moon (oc56@naver.com), Graduate School of Computer Science, Dankook University.

**Daewon Kim (drdwkim@dku.edu), Department of Applied Computer Engineering, Dankook University.

• Received: 2018. 09. 28, Revised: 2018. 11. 25, Accepted: 2018. 12. 10.

다수 복층의 깔때기 모양으로 이루어져 있어 일단 한 번 유인된 하늘소류의 곤충은 자력으로 탈출하기 어려운 구조로 되어 있다. 이러한 트랩을 이용하여 국립산림과학원 주도로 포항과 경주 일원에서 실시한 자체 실험에서 트랩 한 개 당 매개충이 하루에 최대 스물 아홉마리까지 포획되는 효과를 보았고 내부에 갇힌 매개충의 개체 수를 확인하여 소나무재선충병 모니터링 시스템을 고도화하는 등, 보다 차원 높고 정밀한 방제에 이용하고자 노력하고 있다[3].



Fig. 1. Pheromone trap for pine-wilt disease control[2]

그런데 현재 일반적으로 활용되는 소나무재선충 매개충 포획용 트랩들은 대부분 현장에서 포획된 곤충을 모니터링 할 수 있는 기능을 갖고 있지 않아 해당업무 관련 담당자가 직접 현장에 나가서 피해 현황 및 포획된 곤충 개체수 파악 등의 작업을 진행해야 하므로 많은 시간적, 경제적 비용을 필요로 한다. 여기에 덧붙여, 정확한 병충해 감염 시점을 알 수가 없기 때문에 확산 경로를 예측하기가 힘들어져 예방 및 추가 방제 등의 대책 마련이 어려워진다. 이러한 문제점들을 극복하기 위해 본 연구에서는 기존의 페로몬을 이용한 매개충 유인용 트랩에 기능을 추가하여 트랩에 포획되는 소나무재선충 매개충 상황을 원거리에서 단시간 내에 파악할 수 있는 기능을 보유한 스마트 트랩을 개발하고 여기에서 수집된 매개충 또는 여타 곤충의 영상을 분석하고 분류하여 소나무재선충병 확산 방지를 위한 모니터링 시스템 개발에 일조 하고자 하였다.

트랩에 사용되는 페로몬은 매개충인 북방수염하늘소와 솔수염하늘소만을 유인하지 않고 그 외의 다른 하늘소류를 함께 유인하고 또한 바람에 흩날린 꽃잎이나 나뭇잎 등 이물질들이 트랩 내부에 들어오기도 하므로 담당자가 직접 매개충들을 분류하는 작업이 필요하여 모니터링을 위한 짐계가 늦어지는 문제점을 안고 있다. 이를 해결하기 위해서는 포획 통 내부에 들어오는 개체가 매개충인지 비매개충인지 또는 기타 이물질인지 이들의 종

류를 쉽고 빠르게 구분할 수 있는 자동화 된 방법이 필요한데 본 연구를 통해 영상처리와 딥 러닝 기술을 접목하여 분류작업을 진행하였다. 근래 들어 분산처리 기술이 발전하고 GPU(Graphic Processing Unit) 및 메모리의 성능이 향상됨에 따라 많은 컴퓨팅 자원을 필요로 하는 딥 러닝 기술이 발전하였다. 그 중에서도 특히 여러 종류의 영상을 카테고리에 따라 높은 정확도로 분류할 수 있는 기술인 CNN(Convolutional Neural Network)을 이용한 인공지능 기술 영역에서 많은 연구가 이루어지고 있는데, 영상처리 분야에서는 이미지가 갖고 있는 수많은 고유한 특징점들을 동시에 확인할 수가 없어서 비교적 분류 정확도가 저하되는 단점이 존재한다. 이러한 점에 주목하여 소나무재선충 매개충 유인용 페로몬을 이용한 트랩 개발과 더불어 CNN 등의 인공지능 기술을 응용하여 분류 작업을 하는 매개충 모니터링 시스템을 갖춘 분류기 모델을 개발 하였다.

본 논문에서는 소나무 재선충 매개충과 비매개충 그리고 나뭇잎 등의 비곤충인 사물간의 분류 정확도 향상을 위해 이미지 상에서 배경을 제거하고 타겟 오브젝트 영역만을 추출한 후 CNN 기법을 이용하여 분류 작업을 진행하는 인공지능 분류기 모델을 제시하였다. 본 논문은 2장에서 이미지 인식을 위해 사용된 기존의 분류 알고리즘과 CNN 모델 등 선행 연구들을 소개하고, 3장에서 소나무재선충 매개충 포획 및 현황 모니터링을 위한 스마트 트랩 설계 및 개발에 대해 설명하였다. 4장에서는 매개충 인식을 위한 신호처리 및 CNN 분류기 모델에 대해 설명하고, 5장에서는 실험을 통해 얻은 결과를 제시하고 제안된 방법을 검증한다. 그리고 마지막으로 6장에서 본 연구에 대한 결론을 정리하고 향후 연구 방향에 대해 기술한다.

II. Related works

영상 분류를 위한 인공지능 알고리즘으로는 크게 영상의 내용을 잘 표현하는 특징을 추출하여 분류기를 학습시키는 영상처리 기법과 CNN이나 DNN(Deep Neural Network) 등의 고도화된 인공지능 신경망을 사용하여 학습하고 분류하는 딥러닝 기법으로 나눌 수 있다. 영상처리 기법의 경우 HOG(Histogram of Oriented Gradients)[4-5]나 SIFT(Scale Invariant Feature Transform)[6] 등의 기법을 이용하여 특징을 추출하고 이를 SVM(Support Vector Machine)[7]이나 의사 결정 트리(Decision Tree)[8-9], RF(Random Forest)[10] 등의 기법을 이용한 분류기 모델을 통해 학습시켜 이미지를 분류한다. RF[10] 기법은 의사 결정 트리의 단점을 극복하기 위해 만들어진 알고리즘이며, 여러 개의 의사 결정 트리를 합한 앙상블 모델의 형태를 띠고 있다.

RF 기법에서 개별 의사 결정 트리의 학습 및 분류 방법은 기존의 것과 동일하지만 이 경우, RF 내의 모든 의사 결정 트리들이 동일한 내용으로 학습되어 오버피팅 현상을 일으키기 쉬

우므로 Bagging(Bootstrap Aggregating)[11-12] 기법을 사용해 분류기의 일반화 능력을 향상시킨다. 여기서 Bagging이란 기존의 학습 데이터 집합으로부터 균등분포 복원 표본 추출 방식으로서 새로운 학습 데이터 집합을 만들어내는 앙상블 알고리즘의 일종이며, RF가 갖는 의사 결정 트리의 개수만큼의 서로 다른 학습 데이터를 만들어 각각의 개별 분류기가 서로 다른 환경에서 학습을 함으로써 전체 분류기 모델의 일반화 능력을 강화시키는데 큰 역할을 한다. 영상 처리 기법의 경우 이미지로부터 일정한 특징을 추출하고 이를 분류기에 학습시켜 사용하는데, 이러한 방법은 적은 수의 학습 데이터를 사용하여 더 좋은 결과를 내기에 유리하지만 이미지가 갖고 있는 수많은 고유한 특징점들을 동시에 확인할 수 없기 때문에 비교적 분류 정확도가 저하되는 단점이 존재한다. 반면에 이미지 분류에 특화된 CNN을 이용한 분류기 모델은 사람이 미처 보지 못하고 놓치는 영상의 여러 특징점들을 함께 학습하여 분류에 이용하기 때문에 더욱 정확한 분류가 가능하다.

Deng[13]은 농업 분야에서 병해충 방제를 위해 잎사귀 등에 벌레가 내려앉은 이미지로부터 나방이나 사마귀, 여치, 애벌레 등 다섯 가지 해충의 이미지를 분류하는 알고리즘을 제시하였다. 이들은 입력 영상에 대해 저주파 및 고주파를 제거하는 밴드 패스 필터링 알고리즘으로 전처리를 수행하고 LCP(Local Configuration Pattern) 특징을 추출하여 선형 SVM 분류기를 학습하는데 사용하였고, 결과적으로 약 89%의 분류 정확도를 달성하였다. 또한 Ronny[14]는 위성 등을 통해 촬영된 초분광 영상(Hyperspectral Image)으로부터 지표면의 종류를 자동으로 구분하여 도시 계획이나 농경지 조사 등을 위해 사용될 수 있는 알고리즘을 제안하였다. Zhiqiang[15]은 병원의 안과에서 사용되는 흑백 안저 사진으로부터 백내장의 심각성을 Normal, Mild, Moderate, Severe의 네 단계로 나누어 분류하는 연구를 진행하였다. 이 연구에서는 유전 알고리즘(Genetic Algorithm)을 이용하여 분류에 더욱 효과적인 특징에 더 높은 가중치를 부여하는 방법을 고안하였고 SVM 분류기를 통해 특징 벡터를 학습하고 테스트를 진행하였다.

Chan[16]의 연구에서는 이미지 분류를 위해 PCA(Principal Component Analysis) 기법과 DNNs(Deep Neural Networks) 기법을 융합한 PCANet 분류기 모델을 제안하였다. 이 분류기 모델은 입력 이미지에 몇 가지 PCA 필터를 적용해 윤곽 등의 1차 특징을 획득하고 Binary Hashing 과정을 거친 후 히스토그램을 추출해 사람의 얼굴을 분류하기 위한 특징으로 사용하였다. 또한 영상의 특성인 가변성과 모호성 등의 문제들을 고려하여 장면 이미지를 구성하는 Semantic 속성들의 관계를 설정하는 것이 가능한 Hyper-graph 기반의 모델링 기법을 제안한 연구[17]도 있다. 이들은 이렇게 생성된 Hyper-graph로부터 Likelihood-Ratio 기반 특징 벡터를 생성하였고 SVM 분류기를 통해 학습하고 테스트하였다. 또한 이 연구에서는 열 세계의 실내 및 실외 장면 카테고리 구성된 Data-set을 이용하여 테스트를 진행하였고 기존에 사용되던 pLSA(probabilistic Latent Semantic Analysis) 기법이나

BoW(Bag-of-Words) 기반의 특징, 그리고 SPM(Spatial Pyramid Method) 기반의 특징을 사용한 실험 결과에 비해 일정 정도 향상된 이미지 분류 성능을 보였다.

지금까지 검토해 본 관련 연구 내용들을 살펴보면 이미지 분류 작업을 하기 위해서는 크게 두 갈래의 연구 부류로 나눌 수 있다. 그 중 첫 번째는 영상들로부터 특징점 등의 Feature를 추출한 후 영상처리 기법을 통하여 Classification 작업을 진행하는 경우가 있고 두 번째로는 전통적인 NN(Neural Network) 등 다양한 신호처리 기법과 최근 많이 활용되어지는 CNN, DNNs 등의 인공지능 기법을 이용하여 연구를 진행하는 경우를 들 수 있다.

III. Smart Trap design and operation for pine tree pest control and monitoring

1. Smart Trap

현재 소나무재선충 방제를 위해 개발되어 소나무 숲이 있는 현지에 설치된 대부분의 재선충 매개충 포획 트랩들은, 설치 후 일정 시간이 지난 후 해당 업무 담당자가 직접 트랩이 설치되었던 지역에 가서 포획된 곤충들의 매개충 여부 판단과 개체수 확인 등의 모니터링 작업을 위해 일일이 트랩을 수거하여 확인해야 하기 때문에 많은 시간적 경제적 비용을 필요로 한다. 또한 포획된 매개충의 종류와 개체수가 파악된다 해도 정확히 어느 시점에 어떻게 포획 되었는지 알아내기가 어려워져 현 상태의 모니터링 체계로는 매개충의 개체 수 변화나 발생 시점, 지역 및 인근 수목에의 감염 전이 등에 대한 정보 입력이 늦어지고 또, 적절한 시점에 적재적소에 실행해야 하는 추가 방제 등의 대응이 늦어지는 어려움이 있다. 덧붙여, 트랩에 설치된 매개충 유인용 특수 페로몬은 일반적으로 솔수염하늘소와 북방수염하늘소 같은 매개충들을 끌어들이기 위해 제작되고 사용되지만 아직까지는 페로몬의 매개충 유인 능력에 대한 연구 및 개발의 여지가 많이 남아 있어 다른 종류의 하늘소나 나방 등 관리 감독 기관에서 포획을 목표로 하지 않는 곤충들까지도 유인하여 포획하는 일이 자주 발생한다. 이런 문제들로 인하여 담당자가 직접 포획된 곤충들을 손수 확인하고 구분하는 작업을 진행하면서 일일이 수작업을 통해 정리하고 집계하는 모니터링 작업을 하게 된다.

본 연구에서는 이러한 한계와 문제점을 극복하기 위해 스마트한 장치와 기능을 보유하여 해당 작업을 진행하는 '스마트 페로몬 유인 트랩' (줄여서 스마트 트랩)을 설계하고 개발하였다. 무인 상태에서 작동하는 이 스마트 트랩은 포획 통에 재선충 매개충을 비롯한 곤충이나 나뭇잎 등 물체가 들어오는 것을 적외선 센서로 감지한 후 인식하여 순간 스냅샷으로 영상을 촬영하고 그 후 중앙 모니터링 서버로 전송한다. 이 때 전송된 사진

은 인공지능을 이용한 분류 알고리즘에 의해 매개충 여부를 자동으로 확인하는 작업을 거치게 된다. 이렇게 되면 해당업무 담당자가 포획통을 직접 확인하지 않아도 산림청이나 산림과학원 등 수목자원 관리 기관에서는 목표로 하는 곤충의 포획 여부나 시점 등의 구체적인 정보를 실시간으로 확인할 수 있기 때문에 즉각적인 방제 대응을 통해 소나무재선충병의 감염 확산을 효과적으로 차단할 수 있으며 이로 인해 시간 및 비용 절감이 가능하다. 다음 장에서는 스마트 트랩의 설계 구조와 동작 절차 등에 대하여 설명한다.

2. Design of Smart Trap

2.1 Structure

그림 2는 소나무재선충 매개충 포획 및 모니터링을 위한 스마트 장치가 장착된 스마트 트랩이다. 일반적으로 매개충 유인용 페로몬 저장소만을 보유한 그림 1의 트랩에 비해 스마트 장치 부착을 위한 하부 공간이 필요해 아래로 긴 모양을 하고 있다.



Fig. 2. Smart trap for pine-wilt disease control

전체 트랩의 중앙부에 위치한 페로몬 저장소로부터 페로몬이 공기 중에 퍼져 나오면 상부에 위치한 여러 층의 깔때기 모양의 사방 틈 사이로 매개충이 날라들어 부딪힌 후 아래로 떨어지도록 설계되어 있다. 하부로 떨어진 매개충은 적외선 센서에 의해 동작이 감지되어 사진 촬영이 이루어진 후 서보 모터의 제어에 의해 움직이는 지지판의 동작으로 최하부인 매개충 저장소로 떨어져 갖히게 된다. 그림 3은 그림 2의 하단 부분을 확대하여 보이고 있는데 상부에서 페로몬의 유인으로 인하여 떨어진 매개충을 찍는 카메라와 하단으로 매개충을 낙하시키기 위한 서보 모터, 지지대 등의 장치를 나타내고 있다.



Fig. 3. Smart trap's magnified lower detail

그림 3의 (a)는 산림 지역에 실제로 설치되었을 때의 스마트 장치를 확대한 모습이고 (b)는 연구실에서 스마트 트랩의 mock-up을 제작한 후 스마트 장치를 내부에 장착한 모습이다. 그림 4는 스마트 트랩의 주요 동작을 나타내는 순서도를 보이고 있다. 트랩의 최상단부에는 페로몬이 공기중으로 퍼져나가는 통로 역할을 하는 여러 겹의 깔때기가 존재하고 바로 아랫부분에 오랜 시간에 걸쳐 천천히 페로몬을 확산시키는 특수한 페로몬 저장통이 있어 소나무재선충의 매개충을 유인하는 역할을 한다. 페로몬 저장통의 바로 아랫단에는 포획통에 들어온 물체가 잠깐 거쳐 가는 공간이 있는데, 여기서 서로 마주보는 형태의 레이저 모듈과 포토레지스터 쌍 장치에 의해 매개충 또는 사물의 출현 여부가 감지되고 바로 위에 고정되어 있는 카메라에 의해 사진 촬영이 이루어진다.

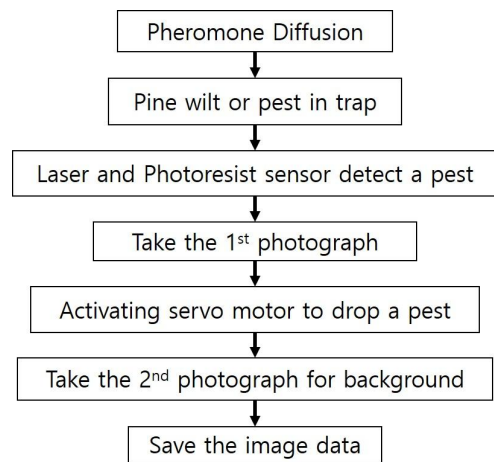


Fig. 4. Operation diagram of the Smart trap

이 단계가 끝나면 서보 모터가 동작해 동물이나 사물을 트랩 하단으로 떨어뜨리고 다시 위치를 원상 복귀함으로써 동물이나 사물 등을 기둔다. 다음 단계로 향후 영상처리를 통한 분류작

업에 사용될 배경 사진을 한 번 더 촬영한 후 저장한다. 이 데이터는 향후 유무선 네트워크를 통해 관계기관 및 연구기관에 후속 대책 마련을 위한 신호처리 등 분류 작업을 위해 전송되어진다. 스마트 트랩 내부의 레이저 감지장치와 카메라, 그리고 서보 모터 제어장치 등의 시스템 제어를 위해 Raspberry-Pi ver. 3[18]를 사용하였으며 이를 통해 모든 센서와 Actuator의 동작이 제어 되도록 하였다. 전원은 태양광 패널을 통하여 집전된 축전지를 통하여 공급 되었다. 다음 장에서는 스마트 트랩 내부에서 스마트 기능을 담당하는 장치의 하드웨어적 구조와 동작 절차 등에 대하여 설명한다.

2.2 Operation

그림 5와 그림 6은 각각 전체 스마트 트랩에서 스마트 기능을 담당하는 부분의 H/W 부품 및 구조도와 동작 절차를 설명하는 Flow-chart를 보이고 있다. 스마트 트랩은 전원이 들어오면 즉시 자동으로 구동되며 네트워크와 사물 감지 센서를 활성화 시킨다. 블루투스 등 네트워크의 사용 가능 여부를 매 순간 탐지하며 만약 네트워크가 사용 가능한 상태라면 바로 이전에 실행했던 데이터 전송작업 시점 이후로 모아두었던 데이터를 모두 전송한다. 이 데이터에는 카메라를 통해 촬영한 스마트 트랩 내부의 매개충이나 사물 등의 전경 및 배경 이미지와 촬영 시간, 촬영된 위치의 GPS 좌표 정보 등이 포함되어 있다.




Fig. 5. H/W parts used in Smart trap

전송된 데이터는 서버의 처리 과정에 의해 분석되고 모니터링이나 사 후 방제를 위한 데이터로써 활용된다. 그와 동시에 레이저 센서 및 photoresist 광학 센서들이 활성화되어 포획 통에 들어온 물체를 감지한다. 이 과정에서 서로 마주보고 있는 형태의 레이저 모듈과 광량을 감지하는 photoresist 센서 세 쌍이 동시에 동작하는데, 만약 어떠한 물체가 해당 공간에 존재하여 레이저를 가린다면 빛이 반대편 센서에 도달하지 못해 감지되는 저항 값이 낮아지게 된다. 따라서 몇 쌍의 photoresist 센서 중에 단 하나라도 저항 값이 일정 임계값 이하로 감지되는 순간이 있다면 동물 또는 사물이 존재한다고 판단해 이후의 과

정을 수행하게 된다. 센서가 사물을 감지하면 가장 먼저 원활한 이미지 촬영을 위해 물체 감지 센서를 비활성화 한 후 포획 통 상단에 장착된 카메라를 통해 대상 물체의 사진을 촬영한다. 이때 촬영은 두 번에 걸쳐 이루어지는데 우선 물체가 포획 통 내부에 처음 들어온 상태 그대로 촬영하여 첫 번째 영상을 획득하고 그 다음, 서보 모터를 동작해 밀판 지지대를 움직임으로써 물체를 포획통의 하단으로 떨어트린 후 다시 촬영하여 두 번째 영상을 획득한다. 사진 촬영 시에는 광량이 부족한 야간에 동작이 이루어질 것을 고려해 적당한 밝기의 LED등을 작동시켜 영상의 밝기를 조절하도록 하였다. 마지막으로 서보 모터를 다시 작동해 밀판 지지대를 원상복귀 시키고 레이저 모듈 및 photoresist 센서를 작동시켜 이 후 감지될 물체를 기다린다. 매번 물체를 감지한 후 첫 번째로 촬영된 사진은 분류 작업 시 전경 사진으로 활용되어지고 두 번째로 촬영된 사진은 배경 사진으로서의 역할을 하게된다.




Fig. 6. Operation flowchart of the Smart trap

이렇게 촬영되어 저장된 후 전송된 데이터는 서버에서 수행되는 전처리 과정 중 배경 제거와 물체 영역 잘라내기 알고리즘을 수행할 시 활용되고 궁극적으로는 소나무재선충 매개충 여부를 판단하고 분류하는 작업에 사용된다. 다음 장에서는 전송된 데이터를 활용하여 신호처리 및 인공지능 학습 과정을 통해 재선충 매개충 여부를 판별하고 분류하는 작업에 대하여 설명한다.

IV. Pine tree pest mediator image classification algorithm using CNN

1. Classification algorithm

스마트 트랩에 포획된 매개충을 포함한 곤충 및 사물들을 찍은 사진은 서버로 전송되어, 적절한 시점에 적재적소에 추가 방제 등 사 후 대책 마련을 위해, 분류 알고리즘을 통해 모니터링 결과를 도출하게 된다. 그림 7은 본 연구를 통해 제시하는 소나무재선충 영상 분류 알고리즘의 전체 분류작업 진행 과정을 요약하여 나타내고 있다. 초반 학습 단계에서는 실험을 위해 미리 확보한 매개충인 솔수염하늘소 및 북방수염하늘소의 사진과 나뭇잎, 꽃잎 또는 나방, 벌 등 기타 매개충이 아닌 곤충들의 사진에 이릅표에 해당하는 레이블을 부여한 데이터 셋을 준비하고, 이 데이터 셋을 이용해 CNN 분류기 모델을 학습한다.

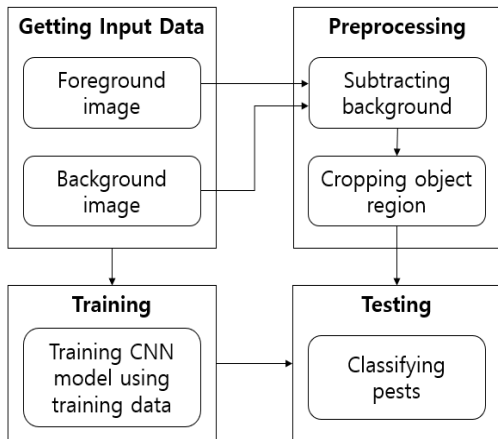


Fig. 7. Process of the classification for pest monitoring

이후 테스트 단계에서는 소나무재선충 매개충 트랩으로부터 획득한 전경 및 배경 사진을 이용해 배경 영역을 제거하고 정확한 물체의 영역만을 추출하여 잘라내는 전처리 과정을 거친다. 마지막으로 미리 학습된 CNN 모델에 전처리된 테스트 데이터를 입력하고 분류 결과를 통해 해당 영상에 소나무재선충 매개충이 포함되었는지 여부를 판별한다. 이러한 분류 결과를 통해 매개충 방제를 위한 차 후 작업 등을 준비할 수 있다.

2. Preprocessing

분류기의 분류 정확도를 향상시키기 위해 스마트 트랩에서 찍은 사진을 배경영상과 전경영상으로 분리하고 물체 영역을 잘라내는 전처리 과정을 거친다. 전경영상은 곤충이나 사물이 포함된 영상을 뜻하고 배경영상은 전경영상에서 곤충이나 사물이 빠진, 오로지 배경만이 존재하는 이미지를 말한다.

2.1 Foreground and background

카메라에 비치는 피사체가 위치한 영역을 정확하게 알아내기 위해 전경과 배경영상의 차이를 구하고 임계값을 적용하여

전경과 배경을 분리한 이진화영상 정보를 획득한다. 회색조 영상간의 차이를 이용한 배경 제거 기법은 일반적으로 널리 사용되지만 RGB 컬러 채널을 Gray-scale 레벨의 채널로 변환하는 과정에서 의미있는 정보의 손실이 불가피하며 이는 배경과 전경의 구성을 혼돈하여 적절한 분리 및 처리를 못하는 등의 약점을 지니고 있다. 본 연구에서는 이러한 잠재적 문제점을 해결하고자 채널별로 각각 적절한 임계값을 적용해 현존하는 방식보다 더욱 민감하게 동작하는 전경 및 배경의 구분 알고리즘을 제시하고자 한다. 표 1은 전경과 배경영상을 분리하기 위해 본 연구를 통하여 고안한 알고리즘으로서, 각각 RGB 채널을 가진 전경 영상 *fgimg*와 배경 영상 *bgimg*, 그리고 이진화를 위한 임계값 상수를 입력 값으로 받아들여 전경과 배경을 분리하고 이진화한 영상을 획득하는 기법에 대한 의사코드를 보이고 있다. 우선 원본 이미지의 모든 픽셀 위치에 대해 전경픽셀 값과 배경픽셀 값으로부터 각각 *r*, *g*, *b*의 색상 채널을 분리하여 절대값의 차이를 구한다.

Table 1. Foreground and background pixel separation algorithm

Algorithm SubtractBackground(<i>fgimg</i> , <i>bgimg</i> , <i>threshold</i>)	
Input	<i>fgimg</i> : foreground image which has RGB channel values <i>bgimg</i> : background image which has RGB channel values <i>threshold</i> : threshold value for binarization
Output	Binarized image by background subtraction
Variables	<i>newimg</i> : array of pixels to store binarized info <i>sub</i> : a pixel info to use temporary
for <i>i</i> in <i>fgimg.length</i>	
<i>sub.r</i> <- Abs(<i>fgimg</i> [<i>i</i>]. <i>r</i> - <i>bgimg</i> [<i>i</i>]. <i>r</i>)	
<i>sub.g</i> <- Abs(<i>fgimg</i> [<i>i</i>]. <i>g</i> - <i>bgimg</i> [<i>i</i>]. <i>g</i>)	
<i>sub.b</i> <- Abs(<i>fgimg</i> [<i>i</i>]. <i>b</i> - <i>bgimg</i> [<i>i</i>]. <i>b</i>)	
if Max(<i>sub.r</i> , <i>sub.g</i> , <i>sub.b</i>) > <i>threshold</i> then	<i>newimg</i> [<i>i</i>] = 1
else	<i>newimg</i> [<i>i</i>] = 0
return <i>newimg</i>	

그 다음 단 하나의 채널이라도 임계값에 도달하는 경우에는 해당 위치의 픽셀을 피사체 영역의 픽셀로 간주하고 만약 모든 채널의 값들이 임계값에 미치지 못하면 배경 영역의 픽셀로 간주하여 흑백 영상으로 이진화 한다. 이러한 과정을 거치고 나면 결과적으로 전경영역은 흰색, 배경영역은 검은색으로 각각 나타나게 된다. 채널별로 임계값을 적용해 이진화 하는 방식의 이러한 기법은 일반적으로 널리 사용되는 회색조 영상간의 차이를 이용한 배경 제거 방법보다 더 민감한 방식이라 사료되며 더욱 정확하고 뚜렷한 전경 영역 추출을 가능하게 할 것으로 보인다.

이 알고리즘에서 사용된 임계값은 여러 회에 걸친 실험을 통해 경험적으로 얻은 적절한 수치를 상수로서 정의한 것인데 전반적으로 밝기 농도가 높아서 전경과 배경 이미지간의 픽셀 값 차이가 커지는 낮 시간대에는 약 50 정도의 높은 임계값을 설

정하였고, 반대로 밝기 농도가 낮아져 전경과 배경 이미지간의 명도 차이가 적어지는 밤 시간대에는 약 30 정도로 비교적 낮은 임계값을 설정하였다. 다음 장에서는 이렇게 분리되어 이진화 된 이미지에 잡음 제거 필터링을 적용하는 과정을 설명한다.

2.2 Noise cancellation

전경과 배경 픽셀이 각각 분리되어 이진화 된 이미지에 목표 물체와 인접한 잡음을 제거하고 물체의 영역을 쉽게 가능하기 위해 팽창연산이나 침식연산[19]과 같은 형태학적 변형 (Morphological Transformation) 기법을 적용한다.

$$A \ominus B = \{z \in E \mid B_z \subseteq A\} \quad (1)$$

$$B_z = \{b + z \mid b \in B\}, \forall z \in E \quad (2)$$

수 식 (1)과 (2)는 흑백 이미지 A에 대해 커널 B를 적용하여 형태학적 침식(Erosion) 연산을 수행하는 식이다. 원본 이미지 위에서 커널을 이동 시켜가며 결과 이미지를 기록하는데, 원본 이미지와 커널이 겹친 영역의 모든 픽셀의 값이 1이라면 결과를 1로 하고, 그렇지 않고 단 하나의 픽셀이라도 1이 아니라면 0으로 기록한다. 이 연산을 통해 이미지 상에서 피사체를 뜻하는 전경(흰색) 영역은 전반적으로 축소되고 흰 점에 해당하는 Salt-noise는 감소하는 효과가 있다.



Fig. 8. Erosion operation using insect image

그림 8은 침식연산을 통해 흑백의 곤충 이미지를 처리한 예시를 보이고 있다. 변형된 이미지인 그림 8의 (b)는 원본 이미지인 (a)에 비해 흰색 영역이 좁아짐에 따라 곤충의 더듬이와 다리 부분이 얇아지거나 아예 없어졌으며 상단의 잡음영역 또한 확연히 줄어들었음을 확인할 수 있다.

$$A \oplus B = \bigcup_{b \in B} A_b \quad (3)$$

수 식 (3)은 흑백 이미지 A에 대해 커널 B를 적용하여 형태학적 팽창(Dilation) 연산을 수행하는 식이다. 침식 연산과 마찬가지로 원본 이미지 위에서 커널을 이동시키며 결과 이미지를 기록하는 방식이며, 원본 이미지와 커널이 겹친 영역의 픽셀 중 단 하나의 픽셀이라도 1의 값을 가지면 결과를 1로 기록하고, 반대로 모든 픽셀의 값이 0이라면 0으로 기록한다. 이 방법은 침식 연산과는

다르게 이미지의 전경 영역은 전반적으로 늘어나고 작은 구멍을 메꾸어 검은색 잡음인 Pepper-noise를 감소시키는 효과가 있다. 그림 9는 팽창연산을 통해 흑백의 곤충 이미지를 변형한 예시를 보이고 있다. 변형된 이미지인 그림 9의 (b)는 원본인 (a)에 비해 흰색 영역이 더 넓어졌고 그에 따라 곤충의 더듬이나 다리 등이 두꺼워지고 상단의 잡음들이 더 커짐을 확인할 수 있다. 일반적으로 잡음 제거를 위해서는 침식연산을 먼저 수행한 후 팽창연산을 수행한다. 그런데 본 연구의 경우 이미지 상의 잡음을 더욱 효과적으로 제거할 수 있는 반면에 곤충의 다리나 더듬이와 같이 가느다랗고 긴 모양의 객체 영역 정보를 잃어버릴 수도 있어서 여기에 덧붙여 보조적인 방법을 취하였다.



Fig. 9. Dilation operation using insect image

이를 위해 전경 및 배경 구분을 통해 추출한 흑백 이미지에 팽창연산을 두 번 적용하여 검은 점 잡음을 줄이고 곤충의 끊어진 다리나 더듬이 영역을 이어준다. 이어서 침식연산을 두 번 적용하여 팽창된 상태의 객체 영역을 원래의 크기로 되돌린다. 이러한 연산 과정을 거침으로써 곤충의 다리나 더듬이 영역에 해당하는 정보를 유지함과 동시에 객체 주변의 미세한 잡음들을 쉽게 정리할 수 있어서 결과적으로는 곤충만의 영역을 적절한 크기로 감싸는 사각형 모양의 영역을 추출해 내기 쉬운 형태의 이진영상이 된다. 이 과정에서 팽창과 침식연산에 사용되는 커널은 모두 3×3의 동일한 크기이며 각 연산의 수행 횟수나 커널 사이즈는 여러 번의 실험을 통해 경험적으로 얻은 최적의 값이다. 다음 장에서는 본 장에서 설명한 잡음 제거 등의 작업 이후 이진영상에서 피사체만이 존재하는 영역을 독립적으로 잘라내는 과정에 대하여 설명한다.

2.3 Foreground subtraction

이 단계에서는 앞서 필터링한 흑백 이미지를 이용해 물체의 크기와 위치를 확정된 후 원본 영상으로부터 해당 영역을 잘라내는 과정을 거치도록 한다. 일반적인 방법으로는 물체의 영역을 탐지하기 위해 분할 정복(Divide and Conquer) 기법을 이용하여 이미지 내에서 각각의 영역을 분할하는 Selective-Search[20] 알고리즘이나, 미리 학습된 요소를 통해 HOG 특징을 필터링하여 목표를 탐지하는 DPM(Discriminatively Trained Part Based Models)[21] 등의 기법들이 있다. 그런데 이들 알고리즘은 분리된 각각의 영역에서 전경 및 배경을 구분하기 위해 SVM 등의 분류기를 추가로 학습하여 사용하여야 하는 불편함이 존재한다.

또한 최근에 높은 탐지 성능을 보유하여 각광받는 R-CNN (Region-based Convolutional Neural Networks) 계열의 딥러닝 기법은 다량의 데이터를 기반으로 한 분류기 학습이 필요하고 연산량이 많아 탐지 속도가 느리다는 단점이 있다. 본 연구에서는 전처리 과정을 통해 대상 이미지가 이진화 된 흑백 이미지이며 내부에 존재하는 목표 피사체가 타 잡음 등에 비해 크기가 큰 편인 연구 내용의 특수성을 고려하여 학습이 필요 없고 실행 속도가 빠른 알고리즘을 고안하여 활용하였다.

Table 2. Algorithm to find the region of an object from a binary image

Algorithm FindBiggestBlob(<i>img</i>)
Input Binary image
Output Rectangle area of biggest object
Variables
<i>blob</i> : array of pixels
<i>blobs</i> : array of blobs
<i>visited</i> : array of pixels
<i>x1</i> , <i>y1</i> , <i>x2</i> , <i>y2</i> : rectangle info of <i>blob</i> , <i>x1</i> and <i>y1</i> are initialized to 0, <i>x2</i> and <i>y2</i> are initialized to 9999
for each <i>pixel</i> in <i>image</i>
<i>visited</i> .Add(<i>pixel</i>)
if <i>pixel</i> is foreground and not in <i>visited</i>
<i>blob</i> ← FindKNearestNeighbor(<i>pixel</i> , <i>k</i> = 4)
<i>visited</i> .Add(<i>blob</i>)
<i>blobs</i> .Add(<i>blob</i>)
for each <i>_blob</i> in <i>blobs</i>
if <i>blob</i> .Count < <i>_blob</i> .Count
<i>blob</i> ← <i>_blob</i>
for each <i>pixel</i> in <i>blob</i>
if <i>x1</i> > <i>blob</i> . <i>x</i>
<i>x1</i> ← <i>blob</i> . <i>x</i>
if <i>y1</i> > <i>blob</i> . <i>y</i>
<i>y1</i> ← <i>blob</i> . <i>y</i>
if <i>x2</i> < <i>blob</i> . <i>x</i>
<i>x2</i> ← <i>blob</i> . <i>x</i>
if <i>y2</i> < <i>blob</i> . <i>y</i>
<i>y2</i> ← <i>blob</i> . <i>y</i>
return Rectangle(<i>x1</i> , <i>y1</i> , <i>x2</i> , <i>y2</i>)

표 2는 배경 영역을 분리한 이진영상을 입력받아 이미지 객체를 감싸는 사각형 영역 정보를 추출하는 기법을 설명하는 의사코드를 보이고 있다. 우선 이진화 된 영상의 모든 픽셀을 순회하며 k-Nearest Neighbor 알고리즘을 수행한 후 이진영상 내에 존재하는 모든 덩어리 객체인 *blobs*를 탐색한다. NN 기법의 k는 상하좌우 픽셀만을 탐색하는 4로 설정하였으며 한 번 순회를 거친 픽셀은 *visited*에 추가함으로써 이후 반복해서 탐색되지 않도록 하였다. 반복문을 통해 가장 많은 개수의 픽셀을 가진 *blob*을 전경객체라 판단하고 *blob* 내부의 모든 픽셀을 순회하며 해당 객체를 둘러싸는 직사각형 영역 정보를 획득하여 반환한다. Cropping 단계에서는 다음 단계에서 활용될 CNN 분류기에서의 원활한 특징 추출을 위해 가장자리에 약간의 여유를 두어 이미지를 잘라내며 이러한 절차를 거쳐 획득된 영상은 추후 이미지 분류기의 입력 데이터로 사용된다. 다음 장에서는 CNN 기법을 이용하여 해당 이미지가 소나무재선충의 매개

충인지 여부를 판별하는 과정에 대하여 설명한다.

3. Pest insects image classification using Convolutional Neural Network

3.1 CNN training and classification algorithm

본 연구에서는 해충에 해당하는 소나무재선충 매개충의 영상 분류를 위해 Tensorflow 프레임워크를 딥러닝 라이브러리로 사용하고 분류기 모델로는 CNN을 사용하였다. CNN은 인간의 뇌에 존재하는 신경세포인 뉴런의 구조를 모방하여 만든 인공 신경망(Artificial Neural Network, ANN)을 기본으로 하고 있다.

$$f(x) = K\left(\sum_i w_i g_i(x) + b\right) \quad (4)$$

수 식 (4)는 일반적인 다중 계층 퍼셉트론(Multi Layer Perceptron, MLP)에서 사용하는 퍼셉트론 하나의 구조를 수학적으로 모델링한 것이다. 이전 노드로부터 전달받은 값 $g_i(x)$ 에 가중치 w_i 를 곱한 후 모든 값을 합하고 편차 b 를 더한 뒤에 활성화함수를 거쳐 다음 노드에 신호를 전달한다. 인공 신경망은 이러한 퍼셉트론들의 집합으로 이루어져 있으며 주어진 학습 데이터를 활용해 각각의 가중치와 편차를 학습함으로써 네트워크 구조를 완성한다. 일반적으로 다중 계층 퍼셉트론을 학습시키기 위해 역전파(Back Propagation) 알고리즘을 사용하는데 이는 경사하강법(Gradient Descent)을 모든 계층에 적용하기 위해 고안된 방법으로서 학습 데이터를 뉴럴 네트워크에 입력값으로 넣어 정방향으로 한번 연산을 수행한 후 그 결과로 나온 예측값과 실제 정답간의 차이인 오차값을 구해 이를 다시 뉴럴 네트워크의 역방향으로 전파하면서 가중치와 편차를 보정해나가는 방식이다.

$$\theta = \theta - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \quad (5)$$

수 식 (5)는 경사하강법 알고리즘을 보이고 있다. θ 는 보정할 파라미터이며 목적함수 $J(\theta)$ 를 미분한 값에 learning rate인 α 를 곱한 만큼의 변화를 주어 목표한 파라미터 값을 수정한다. 일반적으로 퍼셉트론에서 목적함수는 error 함수를 의미하며 여러 번의 보정에 걸쳐 파라미터가 수정됨에 따라 error 값이 점점 최소화되는 결과를 얻을 수 있다. 경사하강법에 미분의 연쇄법칙(Chain rule)을 적용해 역전파 알고리즘으로 편미분하면 각각의 노드에 대한 가중치와 편차 파라미터에 대한 학습 공식을 구할 수 있다.

$$W_{ij}^{(l)} = W_{ij}^{(l)} - \alpha a_j \delta_i^{(l+1)} \quad (6)$$

$$b_{ij}^{(l)} = b_{ij}^{(l)} - \alpha \delta_i^{(l+1)} \quad (7)$$

수 식 (6)과 (7)은 다중 계층 퍼셉트론에서의 가중치와 편차 파라미터를 보정하기 위해 유도된 공식이며 각각의 퍼셉트론은 다음 계층으로부터 전달받은 오류 값인 $\delta_i^{(l+1)}$ 을 이용해 가중치 파라미터 $W_{ij}^{(l)}$ 와 편차 파라미터 $b_{ij}^{(l)}$ 를 각각 새로운 값으로 업데이트한다. 그러나 일반적인 인공신경망은 이미지 분류작업 분야에서 사용하기엔 이미지만이 가진 고유한 지역적, 문맥적 특성을 학습하기가 어려우며 네트워크를 유지하기 위한 파라미터의 수가 지나치게 많아 연산량이 크게 증가한다. 또한 과적합이라 할 수 있는 Over-fitting의 발생률이 높아져 비효율적인 면이 크다. CNN은 이런 문제들을 해결하기 위해 고안된 방법으로서 전통적인 영상처리 기법에서 사용되어져 왔던 필터의 개념을 사용한다.

여기서 필터는 흔히 커널(kernel)이라 불리우며 컨볼루션(convolution) 연산을 통해 이미지의 모든 부분에서 특정한 모양이나 성질이 존재하는지에 대한 여부나 그 특징이 위치한 장소 등을 검출해내는 작업을 담당한다. 또한 하나의 신경망 모델에는 서로 다른 커널이 다수 존재할 수 있으며 각각 상이한 특징을 추출하는 역할을 한다. 따라서 이미지 데이터의 형태를 그대로 유지하면서 작업이 진행되며 학습 및 분류 과정에서 이미지가 가진 공간 정보의 손실을 최소화하므로 이미지 분류 작업을 더욱 효과적으로 할 수 있다.

3.2 CNN model structure

표 3은 본 연구를 통해 고안한 CNN 모델 구조와 학습 가능한 파라미터들을 나타낸다. 총합 세 개의 컨볼루션층 레이어(Convolutional Layer)가 존재하는데 이들 레이어는 학습 데이터로부터 다양한 종류의 특징을 추출받아 학습되며 이후 테스트 단계에서는 입력 이미지에서 해당하는 특징을 추출하는 역할을 수행한다. 첫 번째 Convolutional Layer에서 동작의 보폭을 일반적으로 사용하는 $1 \times 1 \times 1$ 이 아닌 $1 \times 2 \times 2$ 로 적용했는데 이를 통해 자연스러운 서브 샘플링(sub sampling)이 이루어져 학습이 특징 데이터에만 지나치게 치우치게 되는 과적합(Over-fitting) 현상을 방지한다. 또한 Convolution 과정에서 이미지의 가장자리는 0으로 패딩 작업을 하여 특징의 유실을 방지하였다. 컨볼루션을 수행한 이후 활성화 함수로는 ReLu(Rectified Linear Unit) 함수를 사용하였는데 이는 Sigmoid나 Linear 함수에 비해 역전파 학습 과정에서 미분의 수학적 특성으로 인해 계층이 깊어질수록 학습을 통해 전달되는 값이 희석되는 Vanishing Gradient 현상을 방지하는데 유리하여 더 나은 학습 결과를 얻을 수 있게 도와준다. 컨볼루션층 레이어를 거쳐 추출된 특징들은 Pooling layer에 의해 서브 샘플링 과정을 거쳐 입력 데이터의 볼륨을 조절해 과적합 문제를 방지하고 네트워크의 파라미터 수와 연산량을 조절하여 학습 속도를 증가시킨다.

Table 3. CNN Learning and Classifier Model Structure

Layer	Parameter
1. Input	Shape: $N \times 256 \times 256 \times 3$
2. Convolution	Weight: $5 \times 5 \times 3 \times 64$ Stride: $1 \times 2 \times 2 \times 1$
3. ReLU	
4. Max-Pooling	Kernal: $1 \times 3 \times 3 \times 1$ Stride: $1 \times 2 \times 2 \times 1$
5. Convolution	Weight: $5 \times 5 \times 64 \times 128$
6. ReLU	
7. Max-Pooling	Kernal: $1 \times 2 \times 2 \times 1$ Stride: $1 \times 2 \times 2 \times 1$
8. Convolution	Weight: $3 \times 3 \times 128 \times 256$
9. ReLU	
10. Max-Pooling	Kernal: $1 \times 2 \times 2 \times 1$ Stride: $1 \times 2 \times 2 \times 1$
11. Fully Connected	Neurons: 16384×1024
12. Fully Connected	Neurons: 1024×1024
13. Dropout	Rate: 0.5
14. Fully Connected	Neurons: 1024×2
15. SoftmaxWithLoss	Cost Function: Cross-Entropy

여기에서는 오직 Max-Pooling 기법만이 사용되며 이는 특징 값이 클수록 주변의 다른 특징들을 대표해 표현할 수 있다는 개념을 기반으로 하며 Average-Pooling 등의 기법에 비해 좀 더 좋은 결과를 얻을 수 있다. 이 때 첫 번째로 적용되는 Max-Pooling Layer에서는 pooling 커널 사이즈를 일반적으로 사용되는 $1 \times 2 \times 2 \times 1$ 크기가 아닌 $1 \times 3 \times 3 \times 1$ 크기의 커널로 사용하여 pooling 과정에서 손실되는 데이터를 최소화하였다. 마지막으로 Convolutional Layer에서 추출되고 Max-Pooling Layer에 의해 압축된 특징 값은 총 세 개 계층의 뉴럴 네트워크에 입력됨으로써 분류 기능이 향상된다.

3.3 CNN classifier training and test

학습 단계에서는 전체 네트워크에 확률 50%의 Drop-out을 적용하여 뉴런을 비활성화 시킴으로써 과적합 현상을 방지해 실제 테스트 단계에서의 정확도를 향상시킨다. 손실 함수로는 Cross-Entropy를 사용하였고 Adam Optimizer를 통해 오차를 최소화하는 방향으로 학습을 진행하였다. 이 과정에서 64개 단위의 Mini-batch를 사용하였으며 1000 Epoch만큼을 학습하였다. 그림 10은 본 연구를 통해 제시한 CNN 분류기 모델을 실험 단계에서 표 6에 나오는 10번 자료를 이용해 1000 epoch만큼 학습하는 동안 매 epoch 단계(x축 의미)마다 테스트 데이터로 분류 정확도(y축 의미)를 평가해 기록하고 그래프로 표현한 것이다. 이 그래프에 따르면 학습 초기에 가파른 정확도 상승률을 보이지만 일정 횟수 이상의 학습이 진행된 이후에는 반대로 분류 정확도가 떨어지는 현상이 보이는데 이는 지나친 반복 학습에 의해 네트워크가 학습 데이터에 과하게 치중되는 현상에 의해 발생한 문제이다.

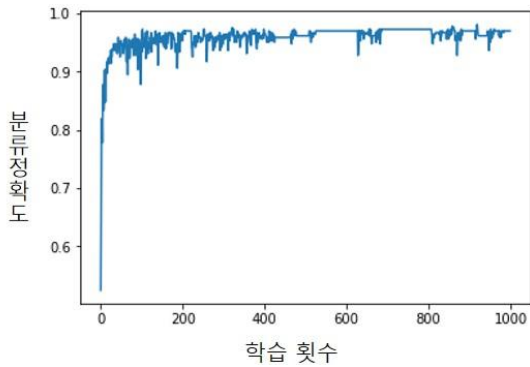


Fig. 10. Classification accuracy change according to change of learning frequency

따라서 본 연구를 진행하면서 매번 1000 epoch의 학습을 거친 네트워크를 사용하지 않고 표 10과 같은 정확도의 추이를 보이는 변화 도표를 보고 적절한 단계만큼 학습한 네트워크를 실제 분류기로 사용하였다. 학습이 완료된 이후 적절하다고 판단되는 네트워크의 파라미터는 파일로 저장하였고 이 후 분류시에 Tensorflow 프레임워크에 내장된 기능을 이용해 학습된 네트워크 파라미터 및 모델 파일을 불러와 네트워크를 복원하고 준비된 테스트 데이터 셋을 입력해 모델의 정확도를 테스트하였다.

V. Experiments and Results

1. Experimental data collection

앞서 제시한 병해충 분류 알고리즘이 실제 관제 시스템 상에서 사용하기에 충분한 정확도를 확보할 수 있는지 검증하기 위해 실험을 수행하였다. 분류 알고리즘이 목표로 하는 소나무재선충 매개충인 솔수염하늘소 및 북방수염하늘소는 연 중 출몰하는 계절이 한정되어 있어 평시에 확보해 놓은 해당 곤충의 생체 및 사체를 이용하여 실험 영상 데이터를 수집 하였다. 그림 11의 (a)는 소나무재선충 매개충인 북방수염하늘소를 나타내고 (b)는 비매개충인 곤충을 나타내며 (c)는 나뭇잎 등 곤충이 아닌 이물질 영상을 나타내고 있다. 여기서 (a)는 1802개, 매개충이 아닌 곤충의 영상 (b)는 959개, (c)는 1000개를 확보해 총 3761개의 이미지 데이터를 확보하였다. 이를 위해 연구실 내부에 하얀색의 넓은 판 위에 투명한 플라스틱 구조물을 설치하여 실제 트랩과 유사한 환경을 구성하였고 매개충 또는 이물질 등을 올려놓은 상태로 촬영을 진행하였다.

Table 4. Acquired experimental data-set

Dataset		Number of positive data (training / testing)
		Number of negative data (training / testing)
A	매개충 / 비곤충	900 (800 / 100)
		1000 (900 / 100)
B	매개충 / 비매개충	800 (720 / 80)
		800 (720 / 80)
C	매개충 / 비매개충 (낮은 조도 환경)	102 (88 / 14)
		159 (136 / 23)

표 4의 A그룹은 매개충과 비곤충을 각각 positive, negative 데이터로 확보하였고, B그룹은 각각 매개충과 비매개충인 일반 곤충, 그리고 마지막으로 C그룹은 일몰 후나 구름이 짙게 끼서 어두워진 환경을 가정하고 매개충과 비매개충 데이터를 확보하였다. 본 실험에서 획득한 각각의 데이터는 약 9:1의 비율로 나누어 트레이닝과 테스트를 진행하였다.


전체 데이터에서 매개충 영상은 positive data로, 비매개충과 비곤충 영상은 negative data로 두 개의 클래스로 구분하여 학습 및 테스트를 진행하였다. C그룹의 경우 가림막을 이용해 빛을 일부 차단한 상태에서 촬영한 사진을 사용하였는데 약간 밝은 정도부터 윤곽만 확인할 수 있는 정도까지의 다양한 밝기로 조도를 조절하여 실험용 데이터를 획득하였다.



(a) 북방수염하늘소(매개충)



(b) 매개충 아닌 곤충



(c) 나뭇잎 등 이물질

Fig. 11. Experimental image data ((a) *Monochamus saltuarius*, (b) General insects, (c) Leaves, etc.)

2. Classification results

앞서 제시한 CNN 레이어 구조의 타당성을 평가하고 해충 클래스와 일반 곤충 그리고 비곤충의 클래스와 같이 두 클래스의 분류기로 목표한 바가 달성 가능한지를 테스트하기 위한 실험을 진행하였다. 일단 표 4에 나타난 데이터를 이용하여 실험을 진행하였다.

Table 5. Classification accuracy evaluation according to various experiment groups

No.	Dataset	# of data	Accuracy(%)
1	A	900 / 1000	88.45
2	B	800 / 800	87.32
3	A, B	1700 / 1800	89.26
4	A Positive	900 / 800	89.83
	B Negative		
5	A Negative	800 / 1000	90.95
	B Positive		
6	C	102 / 159	90.12
7	A, B, C	1802 / 1959	88.93
Average			89.26

표 5는 서로 다른 데이터 그룹인 A, B, C를 각각 또는 positive 데이터와 negative 데이터를 서로 교차하거나 연합하여 실험을 진행하고 여기에 사용된 데이터의 개수와 분류 정확도를 나타낸 것이다. 1번과 2번 실험에서는 각각 A그룹과 B그룹을 이용하여 목표 해충과 나뭇잎 등 비곤충 간의 구분, 그리고 해충과 일반 곤충간의 분류 정확도를 실험하였는데 그 결과 두 실험에서 각각 88.45%, 87.32%의 분류 정확도를 보였다. 3번 실험에서는 A그룹과 B그룹 모두를 사용하여 학습 및 테스트를 진행하였고 89.26%의 정확도를 보여 이 실험을 통해 제안한 CNN이 비곤충 및 일반곤충과 같이 상이한 target을 단일 클래스로 설정했음에도 충분한 분류 성능을 보여주었다.

4번과 5번 실험에서는 A그룹과 B그룹의 positive 및 negative 데이터를 서로 교차하여 테스트를 진행하였고 각각 89.83%와 90.95%의 정확도를 보였다. 어두운 환경을 가정한 C그룹으로 테스트한 6번 실험에서는 90.12%의 분류 정확도를

보였다. 마지막으로 7번 실험에서는 모든 데이터 그룹들을 통합하여 학습 및 테스트를 진행하였고 최종적으로 88.93%의 분류 정확도를 보였으며 모든 데이터 그룹간의 평균 분류정확도는 89.26%였다.

본 연구를 통해 제안하는 CNN 분류기의 Layer 구조가 다양한 환경에서 목표로 하는 해충 영상을 성공적으로 분류함을 확인하였다.

3. Preprocessing results

3.1 Background subtraction results

그림 12는 표 1의 배경 제거 알고리즘을 이용해 전경영역과 배경영역을 분리한 실험 결과를 보여준다. 그림 12의 (a)와 (d)는 스마트 트랩을 통해 수집된 곤충을 포함한 전경영역을 보여주고 있고, (b)와 (e)는 (a)와 (d)에서 곤충이 사라진 배경영역을 나타낸다. 그림 12의 (c)와 (f)는 이들 이미지에 전경 및 배경 분리 알고리즘을 수행함으로써 전경영역은 흰색으로, 배경영역은 검은색으로 표현한 이진화 영상을 나타낸다. 이 실험에서는 경험적으로 적절한 임계값을 적용하여 알고리즘을 수행하였고 피사체에 해당하는 매개충이나 비매개충 또는 이물질들의 윤곽이 뚜렷하게 분리되어짐을 확인할 수 있다.




Fig. 12. Result of background removal ((a),(d): Foreground image, (b),(e): Background image, (c),(f): Separated binary image)

3.2 Noise filtering results

그림 13은 배경제거 알고리즘 수행 이후 팽창연산과 침식연산 등 형태학적 변환 기법을 적용한 결과를 보이고 있다. 전경 및 배경 구분을 통해 추출한 이진화 영상(그림 12 (c) 또는 (f))에 3×3 크기의 커널을 적용한 팽창연산을 두 번 적용하고 (그림 13 (a)와 (b)) 이어서 동일한 크기의 커널로 침식연산을 두 번 수행하여 물체 영역의 크기를 원래 상태로 되돌렸다(그림 13 (c)와 (d)).

그림 13의 (a)와 (b) 과정을 거치면서 목표 물체와 가까운 작은 크기의 잡음들을 물체 영역에 통합시켰고 (c)와 (d) 과정

을 통해 영역의 전반적인 크기를 원상 복구시켰다. 결과적으로 곤충의 다리 영역을 유지함과 동시에 점 같은 잡음이나 그림자 등 주변의 잡음을 손쉽게 정리할 수 있어 곤충의 영역을 감싸는 사각형을 추출하기 쉬운 형태로 만들 수 있게 된다. 그림 13의 (e), (f), (g), (h)의 경우는 3×3 크기의 커널을 이용해 침식 연산 2회 이후 팽창연산 2회를 연속으로 적용한 영상으로 그림 13의 (a), (b), (c), (d)의 형태학적 변환연산 과정을 반대로 수행한 결과이다. 이는 잡음 제거를 위해 일반적으로 많이 사용되는 방법이지만 효과가 좋은 반면에 결과 그림들에 나타나듯이 벌레의 가느다란 다리 영역 정보를 분실하게 됨으로써 본 연구의 경우에는 적절치 못한 접근이라 할 수 있다.




Fig. 13. Results of noise removal through morphological transformation ((a),(b): Result of two consecutive dilations, (c)(d): Result of two consecutive erosions, (e)(f): Result of two consecutive erosions, (g)(h): Result of two consecutive dilations

3.3 Background subtraction results

그림 14는 형태학적 변환을 통한 잡음 제거 필터링이 적용된 영상 (a)에, 표 2에 나타난 물체영역 추출 알고리즘을 수행함으로써, 이미지 내에 목표물이 위치한 좌표를 찾고 곤충을 둘러싼 직사각형 영역의 정보를 추출한 후 (그림 14 (b)) 이를 토대로 원본 영상을 잘라낸 이미지(그림 14 (c))를 만들어 낸 결과를 보이고 있다.




Fig. 14. Result of subject area extraction algorithm ((a) Noise removal image, (b) Rectangle area information extraction, (c) Cropped original image)

이 과정은 전체 이미지에서 불필요한 정보를 제거하고 이미 분류 작업에 필요한 정보만을 남김으로써 분류 정확도의 향상에 도움이 되고자 수행 되는 것이라 할 수 있다.

4. Classification results after object image cropping

이 단계에서는 이미지 상에서 물체 영역을 잘라내는 전처리 과정을 거칠 경우 그렇지 않은 원본 영상을 사용하여 학습 및 테스트 한 경우에 비해 분류 정확도에서 어느 정도 향상이 있는지 확인하기 위해 실험을 진행하였다. 분류기 학습 및 실험을 위해 준비한 데이터 그룹, A, B, C에는 제안하는 알고리즘에 따른 전처리 과정을 수행하기 위한 배경 영상이 존재하지 않기 때문에 별도의 작업을 통해 영상을 잘라내었다. 표 6은 데이터 그룹 A, B, C로부터 물체 영역을 잘라낸 각각의 데이터 그룹 A', B', C'에 대한 학습 및 분류 정확도를 보이고 있다. 매개충과 비곤충 물체를 구분하는 A'그룹에 대한 8번 실험에서는 표 5의 A그룹에 대한 1번 실험에 비해 2.5%의 분류 정확도가 증가하여 100%의 정확도를 보였으며 매개충과 비매개충을 구분하는 B'그룹에 대한 9번 실험에서는 표 5의 B그룹에 대한 2번 실험과 동일한 결과를 보였다. 각각의 데이터 그룹을 혼합하여 사용한 10번 실험 또한 표 5의 3번 실험에 비해 분류 정확도가 0.5% 증가한 98%에 이르렀다. 표 6의 12번과 13번 실험은 각각 표 5의 5번과 6번 실험과 동일하게 100%의 분류 정확도를 보였으며 모든 데이터 그룹을 사용한 14번 실험에서는 표 5의 7번 실험에 비해 0.02% 향상된 98.0%의 정확도를 보였다.

Table 6. Classification accuracy evaluation after cropping the subject area

No.	Dataset	# of data	Accuracy(%)
8	A'	900 / 1000	100.0
9	B'	800 / 800	97.5
10	A', B'	1700 / 1800	98.0
11	A' Positive	900 / 800	98.88
	B' Negative		
12	A' Negative	800 / 1000	100.0
	B' Positive		
13	C'	102 / 159	100.0
14	A', B', C'	1802 / 1959	98.0
Average			98.91

최종적으로 모든 데이터 그룹 간의 평균 분류정확도는 98.91%였다. 이 실험에서는 스마트 트랩에서 촬영한 영상에서 피사체 영역만을 남기고 이미지를 잘라내는 전처리 과정을 수행함으로써 목표로 하는 타겟 분류 작업의 정확도 향상에 많은 도움이 됨을 확인하였다.

5. Classification results using field data

이번 실험에서는 표 5의 데이터 그룹 A와 B에서 매개충 영상 1520장, 비곤충 영상 900장, 비매개충 영상 720장 등 총 3140장의 영상을 활용하여 CNN 분류기를 학습한 후 현장에 설치된 스마트 트랩에서 확보한 영상으로 테스트 함으로써 분류 알고리즘의 성능을 검증하고자 하였다. 그림 15는 필드 상에서 촬영된 이미지에 객체 영역만을 잘라내기 위해 전처리 과정을 수행한 결과를 보이고 있다. 그림 15의 (a)와 (b)는 각각 소나무재선충 매개충 및 배경 사진이며 그림 15의 (d)와 (e)는

매개충이 아닌 일반 곤충류의 사진 및 배경 사진이다. 그림 15의 (c)와 (f)는 각각 (a)와 (b), (d)와 (e) 이미지를 이용하여 피사체 영역만을 남겨두고 잘라내기를 수행한 영상이다. 이렇게 현장에서 각각 매개충 영상 104장과 비매개충 영상을 50장을 확보하였고 총 154 종류의 필드 테스트용 전경 및 배경 이미지에 전처리과정을 수행하였다. Cropping 과정의 수행 여부에 따라 어느 정도의 분류 정확도 차이가 나는지 점검하기 위해 전처리과정 없이 분류작업을 시도하여 두 결과를 비교해보았다.

Table 7. Comparison of classification accuracy before and after cropping the subject area

No.	# of data	Preprocessing	Accuracy(%)
1	Positive:104 Negative:50	w/o Cropping	80.13
2	Testing:77	w/ Cropping	88.25


표 7은 학습된 CNN 분류기에 Cropping 과정 실행 여부에 따라 입력 영상을 달리 하여 테스트를 진행하고 분류 정확도를 표로 비교하여 나타낸 것이다. CNN 분류기는 표 7의 1번 실험에서 Cropping을 하지 않은 이미지에 대해 80.13%의 정확도로 정답을 분류하였고 2번 실험에서는 Cropping 알고리즘을 수행한 이미지에 88.25%의 정확도를 보였는데 이는 전처리 전의 분류 정확도에 비해 8.12% 향상된 결과이다.



(a)



(b)



(c)



(d)



(e)



(f)

Fig. 15. Results of pre-processed images taken in field test ((a) Pine wilt insect image, (b) Background image of (a), (c) Cropped image from (a), (d) General insect image, (e) Background image of (d), (f) Cropped image from (d))

현장에서 확보한 데이터를 CNN 모델에 실험해 본 결과 연구실 내부에서 확보한 영상자료의 분류 결과(표5, 표6)에 비해 다소 부족한 결과를 보였는데 이는 이미지 데이터의 조도에 따른 밝기의 차이, 그에 따른 선명도의 차이, 그리고 야외 촬영에 따른 각 이미지들의 구도 불일치성 등의 이유가 분류정확도에 영향을 끼친 것으로 보인다. 최종적으로 본 연구에서 제안한 방법과 기존의 타 연구 기법과의 비교분석을 위해 k-NN과 SVM (Support Vector Machine) 기법으로 나온 결과를 함께 표 8에 제시하였다.

Table 8. Comparison of classification accuracy among the proposed method, k-NN and SVM.

Methods	Accuracy(%)
k-NN	81.58
SVM	83.65
Proposed	89.35

Table 8에 제시된 바와 같이 본 연구를 통해 제시한 방법은 89.35%의 정확도를 보였고 k-NN은 81.58%, SVM 방법은 각각 83.65%의 분류 정확도를 보였다. 제안한 방법은 배경제거를 통해 핵심영역을 cropping한 자료를 사용한 것이 더 좋은 결과를 도출한 것으로 보인다. 본 실험 결과를 통해 제안하는 배경 제거 및 잘라내기 알고리즘이 물체 영역을 정확히 확보하고 원본 이미지로부터 불필요한 정보를 제거하여 분류에 유용한 정보만을 남김으로써 분류 결과의 정확도 향상에 기여함을 확인하였다.

IV. Conclusions

본 논문에서는 솔수염하늘소나 북방수염하늘소와 같은 소나무 재선충의 매개충을 포획하고 방제 상황을 모니터링하기 위한 스마트 트랩을 개발하고 해당 장치에서 확보한 이미지 데이터에 CNN 기법을 적용하여 매개충 영상 여부를 분류하는 작업 과정에 대하여

서술하였다. 스마트 트랩은 페로몬을 이용해 매개충을 유인하며 곤충 등이 트랩 내부에 들어올 시에 레이저 모듈 및 photoresist 센서 등의 광학 장치를 통해 이를 감지하고 카메라로 타겟 영상을 촬영하여 서버로 전송하는 시스템으로 이루어져 있다. 서버에 전송된 데이터는 이미지 분류 알고리즘을 통해 매개충 여부 판별에 활용되고, 이후 소나무재선충으로 인한 산림 감염 현황 모니터링이나 후속 방제 작업을 위해 활용된다.

본 연구에서는 이미지의 배경을 제거하고 물체 영역만을 잘라내는 전처리 기법과 CNN 분류기 모델을 통해 소나무 재선충 매개충과 일반곤충 또는 비곤충인 물체를 구분하는 기법을 제안하였다. 곤충 이미지 분류기 모델을 학습하고 테스트하기 위해 소나무재선충 매개충 이미지와, 매개충이 아닌 곤충의 이미지, 꽃잎이나 나뭇가지 또는 나뭇잎 등 곤충이 아닌 이물질 이미지 등을 positive 및 negative 데이터 그룹으로 확보하였다. 이 자료들을 이용하여 CNN 분류기 모델을 학습하고 테스트한 결과 평균 89.26%의 분류 정확도를 보였고 목표로 하는 매개충 영상을 효과적으로 분류할 수 있었다. 동일한 데이터 그룹에 이미지 영역 잘라내기 전처리 과정을 수행한 후 테스트 한 결과, 매개충과 일반곤충 간의 분류 실험에서 전처리 과정 없이 테스트한 결과에 비해 평균 9.65% 향상한 98.91%의 분류 정확도를 보였다. 덧붙여, 실제 현장에서의 필드 테스트 결과 전처리 과정의 수행 여부에 따라 80.13%에서 88.25%까지 분류 정확도가 향상되었다.

본 연구에서 활용된 이미지 분류를 위한 CNN 기법은 향후 소나무재선충 매개충의 분류 작업 및 모니터링뿐만 아니라 카메라를 통한 보행자 인식이나 각종 의료영상 내부의 병증 탐색 등 다양한 분야에서 활용될 수 있을 것으로 보인다. 향후 실제 현장에서 획득한 데이터를 모아 트레이닝 데이터 그룹에 추가 할당할 후 inception-mode 1, batch-normalization 등의 기법을 이용해 CNN 모델의 구조를 고도화하고 학습 기능을 강화하는 방식을 통해 분류 성능을 개선시켜 실제 환경에서 사용 가능한 수준의 해충 분류기 모델을 연구하고 개발할 예정이다.

REFERENCES

- [1] Korea Forest Service, "Pine Wilt Disease", http://www.forest.go.kr/newkfsweb/html/HtmlPage.do?pg=/conser/conser_020103.html
- [2] Joongang Ilbo, "Pheromone tempted trap for Pine Wilt Disease mediators", <http://news.joins.com/article/18533453>
- [3] Nongupin Newspaper, "Pine Wilt Insect... 'Captured using pheromone tempted trap'", <http://www.nongupin.co.kr/news/articleView.html?idxno=39211>
- [4] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 20-25 June 2005.
- [5] Scikits-Image, "Histogram of Oriented Gradients", http://scikit-image.org/docs/0.7.0/auto_examples/plot_hog.html
- [6] David G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints", International Journal of Computer Vision, Vol. 60, No. 2, pp. 91-110, November 2004.
- [7] Corinna Cortes and Vladimir Vapnik, "Support-Vector Networks", Machine Learning, Vol. 20, No. 3, pp. 273-297, September 1995.
- [8] J. R. Quinlan, "Induction of Decision Trees", Machine Learning, Vol. 1, No. 1, pp. 81-106, March 1986.
- [9] Dmitry Yu. and Andrey D., "Decision Stream: Cultivating Deep Decision Trees", IEEE-ICTAI, pp. 905-912, 2017.
- [10] Leo Breiman, "Random Forests", Machine Learning, Vol. 45, No. 1, pp. 5-32, October 2001.
- [11] Leo Breiman. "Bagging predictors," Technical Report 421, Department of Statistics, University of California at Berkeley, 1994.
- [12] William Koehrsen, "Random Forest Simple Explanation", <http://medium.com/@williamkoehrsen/random-forest-simple-explanation-377895a60d2d>, 2017.
- [13] Limiao Deng and Renshi Yu, "Pest Recognition System Based on Bio-Inspired Filtering and LCP Features", International Computer Conference on Wavelet Active Media Technology and Information Processing, pp. 202-204, December 2015.
- [14] Ronny Hänsch and Olaf Hellwich, "Feature independent classification of hyperspectral images by projection-based random forests", Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, pp. 1-4, June 2015.
- [15] Zhiqiang Qiao and Qinyan Zhang, "Application of SVM based on genetic algorithm in classification of cataract fundus images", IEEE International Conference on Imaging Systems and Techniques, pp. 1-5, October 2017.
- [16] Tsung-Han Chan and Kui Jia, "PCANet: A Simple Deep Learning Baseline for Image Classification?", IEEE Transactions on Images Processing, Vol. 24, No. 12, pp. 5017-5032, December 2015.
- [17] Sun-Wook Choi and Chong Ho Lee, "Hypergraph Model Based Scene Image Classification Method", Journal of Korean Institute of Intelligent Systems, Vol. 24, No. 2, pp. 166-172, April 2014.
- [18] Raspberry Pi 3, <http://www.raspberrypi.org>
- [19] Jean Serra, "Image Analysis and Mathematical Morphology, Volume 2: Theoretical Advances", Journal

of Microscopy, Vol. 152, No. 2, pp. 597–597, November 1988.

- [20] J.R.R. Uijlings and K.E.A. van de Sande, "Selective Search for Object Recognition", *International Journal of Computer Vision*, Vol. 104, No. 2, pp. 154–171, September 2013.
- [21] Pedro F. Felzenszwalb and Ross B. Girshick, "Object Detection with Discriminatively Trained Part-Based Models", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 32, No. 9, pp. 1627–1645, September 2010.

Authors



Baksan Moon received the B.S., M.S. degrees in Multimedia Engineering, Graduate School of Computer Science, from Dankook University, Korea, in 2016, 2018, respectively. He is now working as a researcher in Department of Applied

Computer Engineering in Dankook University. He is interested in computer engineering, AI, image processing, mobile application programming.



Daewon Kim received the B.S., M.S. and Ph.D. degrees in Electrical Engineering from Chung-Ang University in Korea, University of Southern California, Iowa State University in USA in 1993, 1996 and 2002, respectively. Dr. Kim joined the

faculty of the Department of Multimedia Engineering at Dankook University, Korea in 2004. He is currently a Professor in the Department of Applied Computer Engineering, Dankook University. He is interested in image processing, neural networks, and deep learning including CNN.