

論文

J. of The Korean Society for Aeronautical and Space Sciences 45(9), 794-806(2017)

DOI:https://doi.org/10.5139/JKSAS.2017.45.9.794

ISSN 1225-1348(print), 2287-6871(online)

심층신경망 기반 우주파편 영상 추적시스템 인식모델에 대한 연구

임성민*, 김진형**, 최원섭**, 김해동***

A Study on the Deep Neural Network based Recognition Model
for Space Debris Vision Tracking System

Seongmin Lim*, Jin-Hyung Kim** Won-Sub Choi** and Hae-Dong Kim***

Department of Aerospace System Engineering, Korea University of Science & Technology*,***

IT Convergence Technology Team, Korea Aerospace Research Institute**,***

ABSTRACT

It is essential to protect the national space assets and space environment safely as a space development country from the continuously increasing space debris. And Active Debris Removal(ADR) is the most active way to solve this problem. In this paper, we studied the Artificial Neural Network(ANN) for a stable recognition model of vision-based space debris tracking system. We obtained the simulated image of the space environment by the KARICAT which is the ground-based space debris clearing satellite testbed developed by the Korea Aerospace Research Institute, and created the vector which encodes structure and color-based features of each object after image segmentation by depth discontinuity. The Feature Vector consists of 3D surface area, principle vector of point cloud, 2D shape and color information. We designed artificial neural network model based on the separated Feature Vector. In order to improve the performance of the artificial neural network, the model is divided according to the categories of the input feature vectors, and the ensemble technique is applied to each model. As a result, we confirmed the performance improvement of recognition model by ensemble technique.

초 록

지속적으로 우주파편이 증가하고 있는 상황에서 국가 우주자산을 안전하게 보호하고 우주개발국으로서 우주환경 보호에 관심을 가지는 것은 중요하다. 우주파편의 급격한 증가를 막기 위한 효과적인 방법 중 하나는 충돌위험이 큰 우주파편들, 그리고 임무가 종료된 폐기위성을 직접 제거해 나가는 것이다. 본 논문에서는 영상기반 우주파편 추적시스템의 안정적인 인식모델을 위해 인공신경망을 적용한 연구에 대해 다루었다. 한국항공우주연구원에서 개발한 지상기반 우주쓰레기 청소위성 테스트베드인 KARICAT을 활용하여 우주환경이 모사된 영상을 획득하였고, 깊이불연속성에 기인한 영상분할 후 각 객체에 대한 구조 및 색상 기반 특징을 부호화한 벡터를 추출하였다. 특징벡터는 3차원 표면적, 점군의 주성분 벡터, 2차원 형상정보, 색상기반 정보로 구성되어있으며, 이 범주를 기반으로 분리한 특징벡터를 입력으로 하는 인공신경망 모델을 설계하였다. 또한 인공신경망의 성능 향

† Received : June 26, 2017 Revised : August 16, 2017 Accepted : August 29, 2017

*** Corresponding author, E-mail : haedkim@kari.re.kr

상을 위해 입력되는 특징벡터의 범주에 따라 모델을 분할하여 각 모델 별 학습 후 앙상블 기법을 적용하였다. 적용 결과 앙상블 기법에 따른 인식 모델의 성능 향상을 확인하였다.

Key Words : Space Debris(우주과편), Active Debris Removal(우주과편 능동제거), Deep Neural Network(심층신경망), Feature Encoding(부호화된 특징), Model Ensemble(모델 앙상블)

1. 서 론

2017년 1월 기준, 10cm이상의 인공물체는 약 29,000개로 추정하고 있으며, 그 수는 우주개발이 시작된 이후 지속적인 증가를 보이고 있다[1]. 이는 우주과편과 운용중인 위성과의 충돌을 야기시키며, 충돌로 인한 위성의 기능 상실은 위성운영에 치명적이기 때문에, 국제적으로 우주과편의 증가에 따른 위험성 인식이 재고되는 상황이다. 국내에서도 이러한 상황을 인식하고 국가 위성과 우주과편의 충돌 위험을 분석하고[2], 수명을 다한 위성을 처리하기 위한 폐기기동에 관한 연구[3]를 수행한 바 있으며, 우주 개발국으로써 이에 우주과편 제거가 우주과편의 증가를 근본적으로 완화 시킬 수 있는 대안으로 제안되었으며[4], 이와 관련하여 능동 또는 수동적인 다양한 제거 방법이 연구개발 중에 있다[5]. 능동 제거를 수행하기 위해서는 우주쓰레기와 근접운용상황에서 상대거리 및 자세 등 제거 대상의 운동에 대한 정보와 대상 우주쓰레기의 식별 및 인식을 위한 구조 및 형상 정보 그리고 색상 정보의 획득이 필수적이다. 따라서 우주과편 제거 위성은 RGB-D camera, 3D LiDAR (Light Detection And Ranging), stereo camera 혹은 ToF(Time-of-Flight) camera 등 시각기반의 거리 센서를 탑재해야 한다. 우주환경은 지상과 비교하여, 영상 내 움직임이 역동적이며, 또한 우주과편의 자세가 불안정하고, 임의의 축으로 회전하는 경우, 태양 입사각과 카메라의 시선방향에 따라 목표물을 안정적으로 인식하는데 어려움이 발생한다. 따라서 이를 위해서는 안정적인 인식모델이 요구된다.

한편, 최근 인공지능(Artificial Neural Network, ANN)을 이용한 방법을 적용시켜 다양한 분야에서 성능향상을 보여주고 있다[6]. 기존의 영상인식 문제에서는 SIFT(Scale-Invariant Feature Transform)나 HOG(Histogram of Oriented Gradients)를 이용한 방법을 적용하였으나, 그 성능의 향상이 다소 적었고, 특히, 후처리가 필요하여 다단의 과정이 필요하다[7]. 또한, 기존 방법들은 사전 결정적인 특징정보를 활용하는 방법

로 인식문제를 해결했기 때문에, 광량이 부족한 상황이나 급변하는 환경에서는 그 성능이 떨어지며, 다양한 환경을 만족하는 모델을 생성하는데 한계가 있었다. 하지만 합성곱 신경망(Convolutional Neural Network, CNN) 등 ANN을 기반으로 하는 인식 및 탐지 알고리즘은 복잡한 영상 이해 문제에서 보다 더 정확하고, 더 자세하게 파악할 수 있는 능력을 보여주고 있고[8], 다양한 환경적 요소를 포함한 데이터를 ANN에 적용하여 그 성능이 증가되었다. 또한, GPGPU(General Purpose Graphic Processing Unit)를 활용한 병렬처리 기법으로 통해 보다 빠르고 많은 데이터를 활용할 수 있게 되었다.

항공우주분야에서의 인공지능의 적용은 주로 위성시스템의 고장진단(fault diagnosis)[9]과 재진입 비행체에 인공지능을 이용한 되먹임 선형화 기법을 적용한 연구[10] 등 제어분야, 또는 위성영상에서 집, 자동차 등 물체인식(object recognition) 및 탐지(detection) 분야에 적용하기 위해 위성영상을 보다 쉽게 해석하는 영상분할(image segmentation)과 분류(classification)에 적용하고, 후처리를 통한 해상도 향상을 위한 초해상도기법(Super Resolution, SR)에도 인공지능 기술이 접목되고 있다[11-13]. 그 이외에 지상에서 전자광학센서(electrical-optical sensor)를 이용하여 우주물체의 밝기 측정값을 이용한 분류 연구에도 인공지능을 적용시켰다[14].

우주과편 능동제거는 우주재급유(re-fueling), 우주 부품수리 및 구조(repairing & rescue) 등 위성 서비스의 한 종류로써, 랑데부·도킹(rendezvous·docking), 근접운용(proximity operation) 등의 우주 핵심기술들이 요구된다. 이러한 기술들은 실시간으로 정확한 판단이 이루어져야 하므로 RGB-D 카메라, 3D-LiDAR와 같은 거리 정보 외에 부가적인 형상 및 색상 정보의 획득도 가능한 센서들과 함께 융합, 처리하는 기술에 대한 연구가 많이 진행되고 있다. Han의 연구에서는 Perceptual spatial-space generation model 기반 강화된 Mean-shift 방법을 제시하고, Monte carlo contour 방법을 적용하여 지역필터(local filter)에서 발생하는 차원 문제를 해결하고자 하

였다[15]. F. Rosso의 연구에서는 스테레오 비전 (stereo-vision)을 기반으로 하는 우주과편의 형상 복원에 관한 연구를 수행하였고, Programmable System-on-Chip(SoC)에 1쌍의 카메라를 장착하여 히스토그램 평활화를 수행하고, SIFT를 이용하여 특징점 매칭으로 형상을 복원하는 시스템을 제안하였다[16]. R. Opromolla의 연구에서는 3D 템플릿 매칭 기술(template matching)을 이용하여 비협조 물체의 자세를 결정하는 연구를 수행하였다. LiDAR에서 받은 정보를 점군(point-cloud) 데이터의 3차원 형상으로 나타내고 사진에 획득한 다양한 자세의 3D 점군 데이터들과 무게중심을 일치시킨 후 비교 및 정합하여 정합 비용이 가장 낮은 자세로 결정을 한다[17]. 세 연구에서 제시한 Mean-shift와 SIFT(Scale-Invariant Feature Transform)기법은 연산량이 상당하고, 광량 변화, 시점 변화 등에 취약하여 성능이 제한적이다. A. Petit의 연구에서는 기존의 모델 기반 추적기술(model-based tracking)에서 이용하는 에지 검출(edge-detection)이 3D 모델의 복잡한 형상이나 임의의 모양에 대해서는 제약이 있고, 실시간에 적합하지 않기 때문에 GPU연산 가속 기술과 3D 렌더링(rendering)활용하였다[18]. 또한 알고리즘 검증에 사용한 영상은 가상으로 제작된 영상(synthetic image)들로 알고리즘의 실제 우주환경에서의 동작을 보장할 수 없다는 한계를 가지고 있다.

본 논문에서는 우주과편 능동제거를 수행하기 위한 추적시스템에 적용시킬 인식모델에 대한 연구를 다루었다. 우주과편을 제거하기 위해서는 근접운용 상황에서 지속적으로 안정적인 인식이 요구되며, 기존의 영상으로는 다양한 환경을 만족하지 못해 어려움이 존재하였다. 또한 기존의 연구에서는 다소 연산량이 많고, 성능향상에 어려움이 많은 기술들을 적용하였다. 이러한 이유로 본 논문에서 제시하는 방법은 지상기반 우주환경 테스트베드를 활용하여 타 분야에서 성능향상이 높은 심층신경망을 적용시켜 인식모델의 성능향상과 안정적 인식에 대한 내용을 다루었다.

II. KARICAT 영상 학습데이터

2.1 우주쓰레기 청소위성 테스트베드

2.1.1 5-자유도 지상 테스트베드

한국항공우주연구원에서는 지상기반 우주쓰레기 청소위성 시험을 위한 테스트베드인 KARICAT(KARI CAPture Testbed)을 Fig. 1과 같이




Fig. 1. KARI CAPture Testbed (KARICAT)

개발하였다[19]. KARICAT은 초소형위성의 랑데부/도킹 알고리즘 개발을 위한 5-자유도 지상테스트 베드로서, 자세제어를 위한 3-자유도와 2-자유도 X-Y축 병진운동을 할 수 있는 기능이 포함된다.

플랫폼은 상부와 하부로 나누어지는데, 상부는 위성을 나타내며, 하부는 지상에서 우주환경 모사를 위한 시스템으로 구성된다. 하부는 플랫폼이 지면과 무마찰 상태가 되도록 에어베어링 (flat-air bearing)과 이동을 위한 추력기가 포함되어 있으며, 지면은 강화유리를 이용하여 편평도를 가지는 평판으로 제작되었다. 또한 주위를 검은 천으로 둘러싸고, LED조명을 통해 우주와 유사한 배경으로 구성하였다. GPS신호 모사를 위한 Motion capture system과 플랫폼과의 실시간 데이터 송수신을 위한 지상국 시스템이 포함된다.

플랫폼은 6U급 초소형위성 형태의 시스템 2기로 구성되며, 각각은 청소위성(Chaser)과 우주쓰레기(Target)의 역할을 수행한다. Target 플랫폼은 병진운동과 Z축 회전운동의 3-자유도의 움직임을 통해 우주쓰레기의 텀블링(Tumbling)을 모사하였고, Chaser는 5-자유도를 이용하여 Target을 추적한다.

2.1.2 KARICAT 구성

KARICAT은 우주쓰레기 청소위성의 랑데부·도킹 기술에 필요한 시각기반 자율항법 알고리즘의 개발 및 시험을 목적으로 한다. Target과의 상대운동을 하는 근접 운용상황을 모사하기 위해 위치제어에 액추에이터, 자세제어를 위한 반작용 휠이 포함되며, 현재의 자세정보와 각속도, 각속도 정보를 위한 AHRS(Attitude and Heading Reference System) 센서를 이용하며, 위치정보를 위해 모션캡처 센서를 활용한다. Target을 지속적으로 추적하기 위해서 색상 정보와 깊이 정보를 동시에 획득 할 수 있는 저전력 센서인 ASUS Xtion Pro를 사용하였다.



Fig. 2. Encoded Feature Vector Stream

2.1.3 KARICAT Chaser 탐색 및 추적 알고리즘

KARICAT Chaser는 시각정보를 기반으로 Target을 탐색 및 추적하기 위한 플랫폼으로 scalable KCF(sKCF, scalable Kernelized Correlation Filter)와 SVM(Support Vector Machine) 인식기를 사용한다[20-21]. 입력영상의 모든 영역에 대하여 검출 및 인식기를 적용하는 것은 OBC(On-Board Computer) 연산 능력의 한계로 인해 현실적으로 불가능하다. 이에 다음과 같이 후보영역을 지정하여 선택적으로 검출을 수행한다. Depth image를 입력으로 하여 sobel연산을 통한 깊이 불연속점을 추출하고, 이를 경계로 영상을 분할하여 Target의 후보영역을 지정한다. 그리고 각 후보영역에 대한 특징정보를 산출한다. 산출된 특징정보를 하나의 부호화된 벡터 스트림으로 변환하였으며, 이를 SVM검출기로 대상 우주과편을 검출하도록 설계하였고, 입력되는 깊이 및 색상 영상 열에서 검출된 Target은 sKCF 기반 알고리즘으로 추적하며, 동시에 매 입력 영상에서 우주과편을 지속적으로 검출하여 추적기의 ROI(Region of Interest)를 갱신하여 추적 성능을 향상시켰다.

2.2 영상 객체 조각의 부호화된 특징벡터 데이터셋 구축

2.2.1 기존 CNN기반 인공지능망의 한계

인공지능망은 다층의 비선형 변환 후에 선형적인 분류를 가능하게 하며 학습이 진행될수록 복잡한 실제 모델에 대한 반영이 정확해지기 때문에 최근 주목받고 있다. 특히 합성곱신경망 CNN의 출현으로 인하여 영상과 같이 대량의 입력 정보에 대한 다층구조의 인공지능망의 구현 및 학습이 용이해졌다. 다만, CNN의 경우 고정된 크기의 회선필터를 사용하기 때문에 입력 단의 노드의 수가 가변적이지 않은 고정된 형태로 설계되어야 한다. 따라서 거리에 따른 객체에 대한 영상의 크기 변화에 대응하지 못하는 문제점이 있다. 특히, 본 논문에서 연구하는 근접운용상황에서의 응용은 서비스위성이 대상에 접근하는 과정에서 대상의 영상에 사영된 상의 크기는 급격하게 증가하기 때문에 기존 CNN기반 인식기를 그대로 적용할 수 없다. 이러한 문제를 해결하기 위해 본 논문에서는 거리에 따라 크기가 다

른 영상 객체 조각에 대한 부호화된 고정된 크기의 특징 벡터를 입력으로 하는 인공지능망을 설계하였다.

2.2.2 영상 객체 조각의 부호화된 특징벡터

인공지능망을 훈련하기 위한 데이터셋 구축을 위하여 KARICAT에서 Xtion camera를 통해 획득한 깊이 및 색상영상을 깊이 불연속성을 기준으로 영역을 분할하고, 분할된 영역의 3차원 표면적이 Target의 정보와 근사한 영역들을 후보 영상 객체 조각으로 추출하였다. 후보 영상 객체 조각은 대상의 거리에 따라 영상 평면에서 상의 크기가 일정하지 않기 때문에, Fig. 2와 같이 인공지능망에 입력이 용이한 형태인 고정된 길이의 벡터 스트림으로 부호화하였다.

부호화된 특징 벡터 스트림은 크게 두 가지 정보를 포함하고 있으며, 대상의 고유한 특징을 최대한 추출하기 위한 목적으로 선정하였다. 깊이 영상으로부터 추출한 3차원 및 2차원 구조 정보, 그리고 색상 영상으로부터 추출한 색상 및 밝기 정보이다. 세부적으로는 후보 객체 조각의 깊이 영상으로부터 점군을 생성하고, 각 점에 대한 지역적 법선 벡터를 산출하여 후보 객체의 3차원 표면적을 계산한다. 그리고 점군데이터에 대하여 주성분 분석기법(Principal Component Analysis, PCA)를 적용하여 세 방향의 주축의 길이를 획득하고, 영상평면 상의 후보 객체 영역의 외접 직사각형과 객체 영역의 내부 화소단위 면적의 비율을 계산한다. 다음으로 후보 객체 조각의 색상 영상으로부터 색상도수분포(hue histogram)과 평균 색상포화도(saturation) 및 평균 명도(intensity)를 계산한다. 특


Table 1. Components of Feature Vector

Parameter	Bytes	Type[size]
3D Surface Area	4	float[1]
Label Area Ratio	4	float[1]
PCA based Direction XYZ Vector	12	float[3]
Average Saturation	4	float[1]
Average Value	4	float[1]
Hue Histogram	512	float[128]
Total	540	

징 벡터를 이루는 각 요소들의 크기 및 변수형은 과 같다

인공신경망 기반 검출 및 인식기는 일반적으로 지도학습에 의해 훈련된다 따라서 인공신경망 기반 검출 및 인식기 모델 구축을 위해 망에 입력되는 데이터와 망에서 최종적으로 출력되는 참값의 쌍에 대한 데이터셋을 구축해야 한다 본 연구에서는 에서 대상 우주쓰레기를 자유도 평면에서 이동시키고 동시에 다양한 시점에서 대상을 촬영했으며 대상이 아니면서 표면적이 비슷한 대상들도 다수 촬영하였다 촬영된 영상으로부터 깊이 불연속성을 기준으로 분할한 영상 객체 조각 데이터셋을 획득하였다

은 영상알고리즘의 검출기로부터 생성된 의 영상 조각을 나타낸다 생성된 특징벡터들은 심층신경망을 지도학습하기 위해 수작업으로 대상체의 우주쓰레기 여부를 판별하여 학습 데이터셋을 구축하였다 의 와 같이 여러 시점에서 촬영하여 대상과의 거리에 따른 크기 변화와 조명과의 자세 차이에 따른 색상 변화를 포함하는 영상들 로 결정하였다 한편 와 같이 센서 오류로 색상정보가 심하게 왜곡되거나 대상 우주쓰레기 외에 다른 객체가 포함되거나 대상 우주쓰레기와 전혀 다르지만 표면적이 유사한 객체에 대한 영상은 로 구분 지었다 영상은 동일한 대상 우주쓰레기에 대하여 태양입사각과 카메라의 시선방향에 따라 달라지는 색상 변화가 반영되어 있으며 비협조적으로 텀블링하는 상황을 가정하여 촬영하였다 우주공간에서 우주쓰레기는 경우에 따라 급격한 움직임이 발생할 수 있기



때문에 움직임에 의한 블러 가 발생한 영상과 의 일부 형상에 대해 획득한 영상도 학습데이터로 지정함으로써 보다 강인한 모델의 학습이 이루어지도록 데이터셋을 구축하였다 영상은 영상 검출기가 정상적으로 검출하지 못한 패치와 영상정보를 모두 획득하지 못하거나 센서오류로 인하여 영상 색상이 제대로 표현되지 못한 영상을 포함한다 그 외에도 크기가 유사하지만 대상 우주쓰레기와는 구분 지어야 하는 급 초소형위성과 테스트베드의 체결부가 함께 검출된 경우도 모두 영상으로 판단하여 인공신경망 모델이 실제 상황에서 외란에 강인하도록 지도학습에 사용할 데이터셋을 구축하였다

본 연구는 영상 및 깊이 정보를 입력되는 조각 그대로 사용하지 않고 형상 및 색상 정보를 추출하여 하나의 특징 벡터로 부호화된 것을 사용하는 심층 인공신경망을 설계하였다 추가적으로 인공신경망의 성능을 극대화하기 위하여 특징에 따라 신경망을 다양하게 분리하여 훈련한 후 각 모델을 결합하여 재훈련시키는 앙상블 기법을 적용하였다

입력되는 데이터에 따른 신경망의 분리에 의한 성능 향상을 확인하기 위하여 와 같이 입력되는 부호화된 특징 벡터를 분할하였다 순번에 따라 은 부호화된 특징 벡터의 분할 없이 하나의 신경망 모델을 사용하였으며 부터 까지는 구조정보와 색상정보를 구분 지어 분할된 형태로 다수의 신경망 모델을 설계 하였다

모델에 입력된 전체 데이터들은 에서 각 모델에 맞게 부호화된 특징 벡터가 분할되고 이후 연결되는 신경망 계층들도 분할된 형태의 신경망이 출력 단에서 하나로 통합된 구조를 갖는다 이때 학습방법의 차이에 따른 성능 평가를 위해 전체 망을 하나의 통합된 망으로 학습시키는 경우와 독립적으로 학습시킨 후 출력 계층을 결합하여 전체적인 학습을 다시 한 번 수행하는 경우로 나누어 학습을 진행하였다

각 는 입력데이터인 부호화된 특징 벡터의 분할에 따라 그 형태가 상이하게 결정된다

Table 2. The Separation cases of Feature Encoding by Characteristic of Feature

case	Composition of Feature Encoding				
1	Area	PCA	Sat.	Val.	Hue
2	Area	PCA	Sat.	Val.	Hue
3	PCA	Area	Sat.	Val.	Hue
4	Area	PCA	Sat.	Val.	Hue
5	Area	PCA	Sat.	Val.	Hue
6	Area	PCA	Sat.	Val.	Hue
7	Area	PCA	Sat.	Val.	Hue
8	Area	PCA	Sat.	Val.	Hue

*Sat. : Saturation * Val. : Value

case 1과 case 2-4, case 6은 각각 Fig. 4-5와 같은 형태를 가지며, 3개 이상의 부호화된 특징 벡터로 나누어지는 case 5 및 case 7-8의 경우, Fig. 5에서 적색 사각형이 포함하는 부분이 확장된 구조를 가진다.

case 1의 경우 데이터가 입력 레이어를 통해서 NN모델에 입력받으면, 입력된 각 요소는 Batch Normalization layer를 거치게 된다. 이 layer에서는 이전 layer의 각 batch의 활성화 함수 결과를 정규화 시키는 것으로 평균 0, 표준편차 1에 가깝도록 조정한다. Batch Normalization layer은 신경망 모델을 학습시킬 때, 파라미터들의 크기에 영향을 받지 않는 특징을 가지기 때문에, learning rate를 크게 결정하여도 안정성이 저하되지 않아 빠른 학습이 가능하다는 장점을 가진다. 또한, regularization의 역할이 가능하기 때문에 학습효과는 좋지만 학습속도가 다소 느려지는 dropout을 대체하여 학습속도를 향상시킬 수 있다. 다음 layer는 Densely connected layer로, layer의 입력 노드와 출력 노드의 가능한 모든 연결에 대한 weight와 bias를 이용하여 활성화 함수(activation function)를 적용한다. 그 이후, batch normalization과 activation function을 한 번 더 수행한 후 dropout을 적용한다. dropout은 고전적인 인공신경망의 문제점 중 하나인 과적합(over-fitting)문제를 방지하는 역할로써, layer의 일부 노드를 무작위로 연결에서 제외시켜 보다 나은 성능을 제시한다. 마지막으로 Fully-Connected layer를 통해서 모든 layer를 연결하고 입력이 positive인지 negative인지 판별하게 된다.

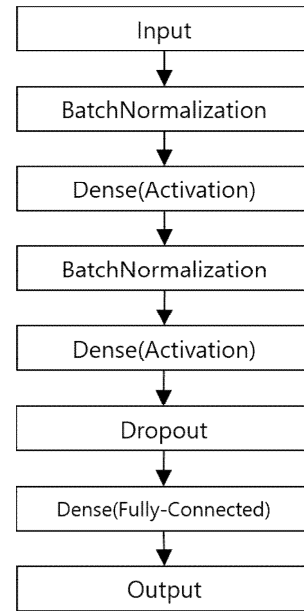


Fig. 4. Neural Network Architecture of Layer No. 1

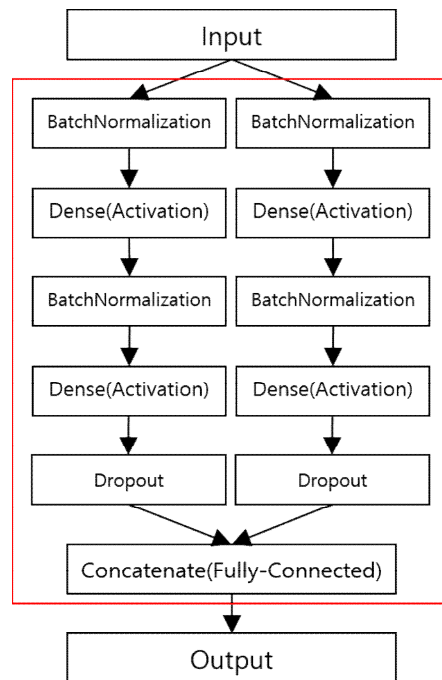


Fig. 5. Neural Network Architecture of Layer No. 2-4 & 6

case 2-8의 분할된 인공신경망 모델의 경우, Fig. 5의 적색 사각형이 포함하는 영역에서 차이가 발생한다. 각각의 layer 구성은 동일하나 Input layer의 각 데이터들은 특징에 따라 분할된 부호화된 특징 벡터에 따라 분리된다. 마지막 Fully-Connected에서는 Concatenate layer를 통

Table 3. Parameter of the Model by Separation case

Case Layer	Feature Encoding Composition			
1	Area PCA Sat. Val. Hue			
AF 1	ReLU, output : 64			
AF 2	ReLU, output : 32			
Drop	drop rate : 0.25			
FC	Sigmoid, output : 2			
2	Area	PCA Sat. Val. Hue		
AF 1	ReLU, 64	ReLU, 64		
AF 2	ReLU, 32	ReLU, 32		
Drop	0.25	0.25		
FC	Sigmoid, output : 2			
3	PCA	Area Sat. Val. Hue		
AF 1	ReLU, 64	ReLU, 64		
AF 2	ReLU, 32	ReLU, 32		
Drop	0.25	0.25		
FC	Sigmoid, output : 2			
4	Area PCA	Sat. Val. Hue		
AF 1	ReLU, 64	ReLU, 64		
AF 2	ReLU, 32	ReLU, 32		
Drop	0.25	0.25		
FC	Sigmoid, output : 2			
5	Area PCA	Sat. Val.	Hue	
AF 1	ReLU, 64	ReLU, 64	ReLU, 64	
AF 2	ReLU, 32	ReLU, 32	ReLU, 32	
Drop	0.25	0.25	0.25	
FC	Sigmoid, output : 2			
6	Area PCA Sat. Val.	Hue		
AF 1	ReLU, 64	ReLU, 64		
AF 2	ReLU, 32	ReLU, 32		
Drop	0.25	0.25		
FC	Sigmoid, output : 2			
7	Area	PCA	Sat. Val.	Hue
AF 1	ReLU, 64	ReLU, 64	ReLU, 64	ReLU, 64
AF 2	ReLU, 32	ReLU, 32	ReLU, 32	ReLU, 32
Drop	0.25	0.25	0.25	0.25
FC	Sigmoid, output : 2			
8	Area	PCA	Sat. Val.	Hue
AF 1	ReLU, 64	ReLU, 64	ReLU, 64	ReLU, 64
AF 2	ReLU, 32	ReLU, 32	ReLU, 32	ReLU, 32
Drop	0.25	0.25	0.25	0.25
FC	Sigmoid, output : 2			

*AF: Activation Function *Drop : Dropout *FC : Fully-Connected

해서 앞단의 결과를 결합한 후 Densely connected layer를 연결하여 최종적인 결과를 계산한다. Concatenate는 layer에 입력되는 분리된 input들을 병렬적으로 적층하여 하나의 결합된 layer로 변환해주는 역할을 한다. 각각의 모델을 구성하는 활성화함수, 노드의 수, drop rate는 Table 3과 같은 파라미터로 설계되었다.

3.2 Neural Network 결과 및 해석

3.2.1 해석 환경

설계된 Neural Network의 해석은 Python기반의 Google™에서 제공하는 Tensorflow®를 이용하였고, 추가적으로 Keras®를 이용하였다. 두 가지 모두 딥러닝을 위한 오픈소스 라이브러리이며, Keras®는 Deep Neural Network를 보다 간소한 절차에 의해 설계하여 테스트할 수 있도록 지원한다[22-23]. Tensorflow®는 multi CPU와 GPU를 지원하고, C++, Python언어를 기반으로 Nvidia™의 CUDA 플랫폼을 활용하여 보다 빠른 병렬처리가 가능하도록 하였으며, Linux, macOS, Windows 등 PC뿐만 아니라 모바일 OS인 Android, iOS 등에서도 지원한다. Keras는 Python기반의 라이브러리로 Tensorflow, Theano, MXNet 등 다양한 딥러닝 플랫폼에 적용가능하다.

학습에 사용한 하드웨어는 프로세서 i7-7700 (3.6GHz), 메모리 16GB RAM(DDR4, 8GB×2), 그래픽 처리장치는 GTX1060 6GB이며, 개발환경은 운영체제 Linux Ubuntu 16.04 64bit, Tensorflow 1.0.0, Keras 2.0.2, Anaconda 4.3.0(Python 3.5.2)을 이용하였다.

실험에 이용된 영상정보는 총 20,035장이며, 이중 학습용 영상은 18,000장, 모델 검증용 영상은 2,035장이며, 분류 클래스 수는 2개 (Positive, Negative)이다. 근접운용상황에서 획득 가능한 영상의 형상과 색상정보를 추출한 부호화된 특징을 이용하였으며, 학습용 데이터에서는 Positive 7,719개, Negative 10,281개이며, 모델 검증용 데이터에서는 각각 364개, 1,671개로 구성되어 있다.

3.2.2 Feature Encoding 모델 결과

Feature encoding에 따른 학습모델의 성능 실험은 50회 반복하여 학습과 검증을 수행하였으며, 매 반복마다 학습과 검증에 대한 accuracy와 cross-entropy loss결과를 Fig. 6과 같이 나타내었다. Accuracy는 미리 분류된 영상데이터의 label과 신경망 모델의 결과와 비교하여 정확도를 판단하는 성능지표이다. 손실

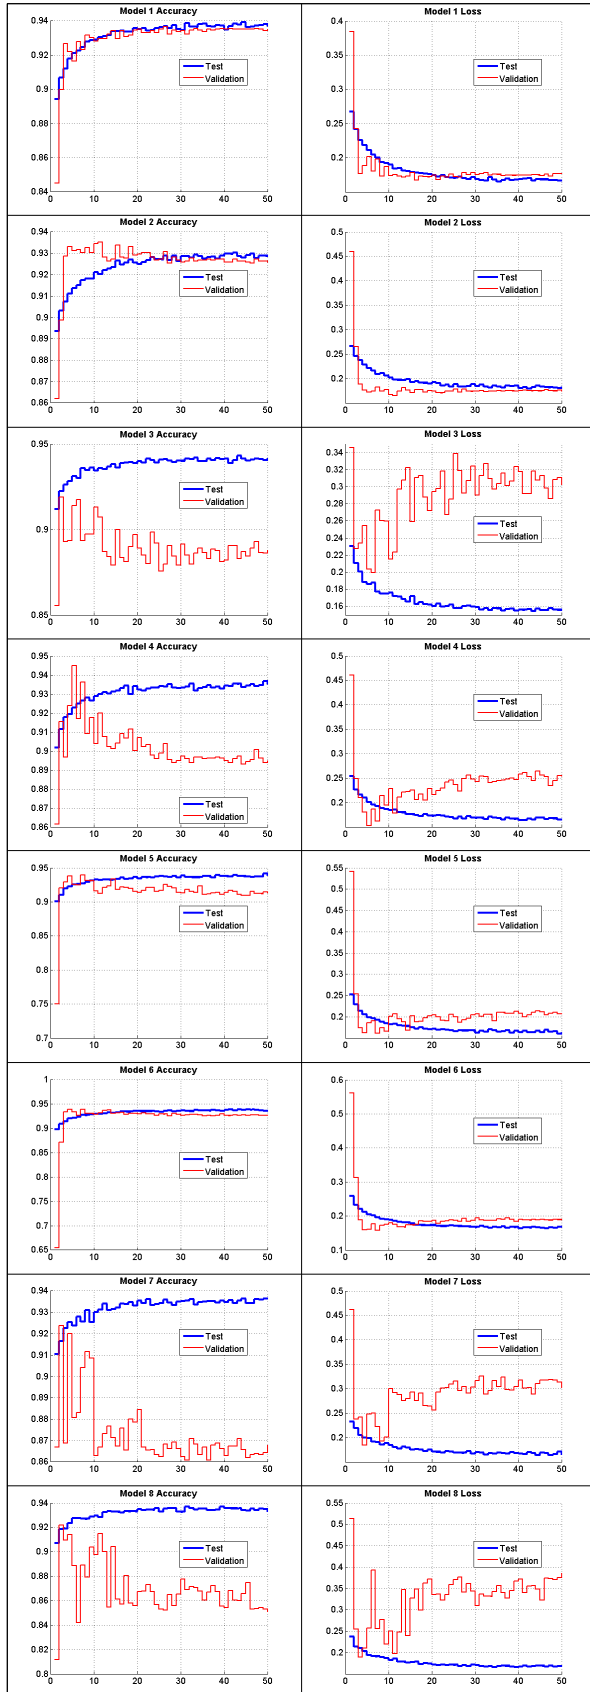


Fig. 6. Accuracy & Cross-Entropy Loss of the Model No. 1-8

함수(loss function)은 현재의 모델이 이상적인 모델과 비교하였을 때, 그 차이를 정의하기 위한 함수로 평균 제곱 오차(mean squared error), 평균 절대 오차(mean absolute error), 교차엔트로피(cross-entropy) 등이 있다. 본 논문에서는 확률분포의 무작위성을 설명하는 용도로 사용되는 엔트로피(entropy)기반으로 2개의 확률분포의 이질성 정도를 나타내는 교차엔트로피방법을 활용하였다. 두 확률분포가 유사할수록 작은 값을 나타내며, 항상 양의 값을 가지며, 2개의 확률분포 p 와 m 에 대한 수식은 다음과 같이 표현한다.

$$H(p, m) = - \sum_i^n p(x_i) \log(m(x_i)) \quad (1)$$

모델의 학습 성과 검증 결과는 Table 4와 같으며, 각 모델의 8가지 case의 학습결과 cross-entropy 0.16 내외, accuracy 약 93% 내외로 나타났으며, 학습모델 간의 비슷한 학습 결과가 나타났지만, 2,035장의 검증 데이터를 이용하여 검증을 수행한 결과는 각 모델별로 다른 결과를 보여주었다. 소수 특징을 기준으로 분리한 case 3, 4, 7, 8의 경우, 학습모델의 accuracy와 loss는 적절한 값으로 수렴하였으나, 실제 검증 데이터를 통한 결과는 학습 결과에 미치지 못하는 결과를 보여주고 있으며, 50회 반복에서도 수렴하지 못하는 결과를 보여주었다. 반면에, 특징을 분리하지 않은 case 1과 가장 많은 비율을 가지는 Hue 특징으로 분리한 case 6의 경우, 초반에는 검증결과가 학습결과보다 accuracy는 더 높게, cross-entropy loss는 더 낮게 나오는 결과가 보였

Table 4. Accuracy & Loss for each Model

Case	Train set		Validation set	
	Loss	Acc.	Loss	Acc.
1	0.1682	0.9368	0.1767	0.9351
2	0.1830	0.9286	0.1743	0.9258
3	0.1555	0.9417	0.3023	0.8880
4	0.1672	0.9351	0.2542	0.8948
5	0.1630	0.9386	0.2076	0.9130
6	0.1682	0.9366	0.1890	0.9268
7	0.1648	0.9368	0.3024	0.8678
8	0.1691	0.9328	0.3851	0.8511

고, 30회 이후 수렴함으로써 보다 낮은 결과를 보였다. 이는 특징을 분리해서 입력을 받을 경우, 해당 모델들의 과적합 문제가 발생하거나 back-propagation중에 소수 특징에 대한 반영이 적어져 발생한 문제로 사료된다.

3.3 앙상블 기법에 의한 인식 성능 개선

3.3.1 모델 앙상블

Feature encoding에 따른 학습모델의 분리를 하지 않은 case 1에 비해 높은 성능을 보이지 못해 Model Ensemble기법을 이용하여 학습모델의 개선시키고자 하였다. 앙상블학습법(ensemble learning method)은 기계학습(machine learning)에서 다수 학습 알고리즘들을 함께 사용하는 방법으로 따로 사용하는 경우보다 더 좋은 예측이 가능한 방법이다. 본 연구에서는 feature encoding을 기반으로 각각의 학습 모델을 만들고 이를 결합하는 방법을 수행하였다. 앞선 방법은 단순히 데이터를 분리하여 모델내부에서 합쳤기 때문에 모델 내

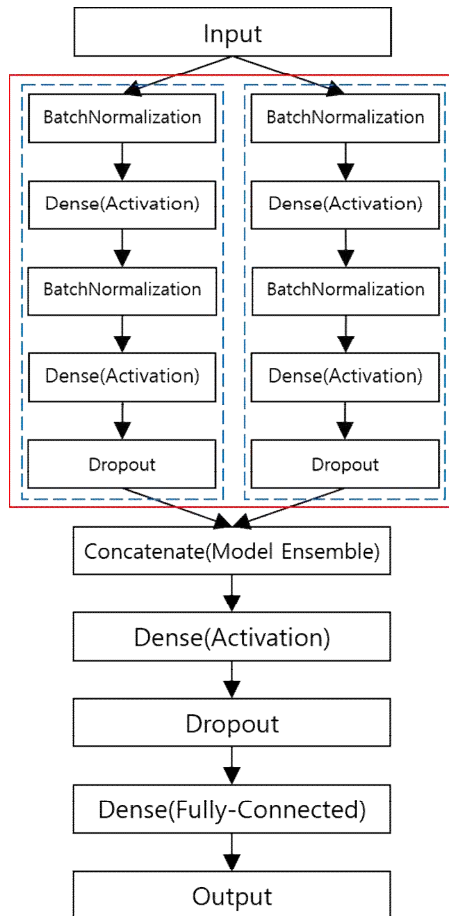


Fig. 7. Model Ensemble Neural Network Architecture of case 2-4 & 6

Table 5. Parameter of the Ensemble Model by Separation case

Case. Layer	Feature Encoding Composition			
E2	Area	PCA Sat. Val. Hue		
AF 1	ReLU, 4	ReLU, 64		
AF 2	ReLU, 2	ReLU, 32		
Drop	0.5	0.5		
FEFC	Softmax, 2	Softmax, 2		
E3	PCA	Area Sat. Val. Hue		
AF 1	ReLU, 4	ReLU, 64		
AF 2	ReLU, 2	ReLU, 32		
Drop	0.5	0.5		
FEFC	Softmax, 2	Softmax, 2		
E4	Area PCA	Sat. Val. Hue		
AF 1	ReLU, 8	ReLU, 64		
AF 2	ReLU, 4	ReLU, 32		
Drop	0.5	0.5		
FEFC	Softmax, 2	Softmax, 2		
E5	Area PCA	Sat. Val.	Hue	
AF 1	ReLU, 8	ReLU, 4	ReLU, 64	
AF 2	ReLU, 4	ReLU, 2	ReLU, 32	
Drop	0.5	0.5	0.5	
FEFC	Softmax, 2	Softmax, 2	Softmax, 2	
E6	Area PCA Sat. Val.	Hue		
AF 1	ReLU, 16	ReLU, 64		
AF 2	ReLU, 8	ReLU, 32		
Drop	0.5	0.5		
FEFC	Softmax, 2	Softmax, 2		
E7	Area	PCA	Sat. Val. Hue	
AF 1	ReLU, 4	ReLU, 4	ReLU, 64	
AF 2	ReLU, 2	ReLU, 2	ReLU, 32	
Drop	0.5	0.5	0.5	
FEFC	Softmax, 2	Softmax, 2	Softmax, 2	
E8	Area	PCA	Sat. Val.	Hue
AF 1	ReLU, 4	ReLU, 4	ReLU, 4	ReLU, 64
AF 2	ReLU, 2	ReLU, 2	ReLU, 2	ReLU, 32
Drop	0.5	0.5	0.5	0.5
FEFC	Softmax, 2	Softmax, 2	Softmax, 2	Softmax, 2
Ensemble				
AF 3	ReLU, 64			
Drop	0.5			
EFC	Sigmoid, output : 2			

*FEFC : Feature Encoding Model Fully-Connected
 *EFC : Ensemble Model Fully-Connected

에서 back-propagation을 수행 시 weight가 전체 결과에 대해서 변경이 이루어지지만, 모델 앙상블을 통해서 학습할 경우, 각 모델의 결과에 따라서만 weight가 조정이 된다. 따라서 다른 feature encoding의 영향이 적고 자기의 특성을 보다 잘 반영할 수 있다. 모델 앙상블의 신경망 구조는 앞선 구조와 유사하나 Fig. 7과 같이 다소 차이점이 있다. 앞선 모델과 같이 빨간 박스의 내부 모델들은 feature encoding의 개수에 따라 2~4개로 나누어지는 것은 동일하나, 파란박스 각각은 하나의 모델로 이루어지고, 사전에 해당 feature encoding으로 학습 모델을 생성한다. 생성된 각각의 모델은 각 case에 맞게 로드하고, 앙상블을 거친다. 앙상블 이후 Fully-Connected layer로 모든 모델을 연결하고, 반복을 통해서 발생할 수 있는 과적합 문제를 방지하기 위해 Dropout layer를 거친 후 최종적인 분류 결과를 출력하도록 설계하였다. 각각의 모델은 Table 5와 같은 파라미터로 구현되었다. 해석은 3.2.1에 제시된 것과 동일한 환경에서 이루어졌다.

3.3.2 모델 앙상블 결과

모델 앙상블의 학습 및 검증의 반복 회수는 앞선 Feature encoding 학습과 동일한 50회 수행하였으며, 이전 학습모델에서 사용한 동일한 학습데이터와 검증 데이터를 이용하였다. 매 반복에 대한 각 case별 accuracy와 cross-entropy loss 결과 Fig. 8과 같이 정리하였으며, 모델 학습과 검증의 결과는 Table 6과 같다.

단순 모델에 비해 모델 앙상블의 학습결과는 loss가 0.24 내외, accuracy가 0.91 내외로 나타났으며, loss는 최대 0.0896(case 7&E7) 증가, accuracy는 0.0357(case 7&E7) 감소한 결과를 나타냈다. 하지만 검증 모델에서는 반대로 loss 0.13(case 2&E2) 감소, accuracy 0.0422(case 2&E2) 증가하여, 각각 0.20, 0.92 내외의 결과를 보였고, 앞선 모델에서 50회 반복 동안 수렴하지 못했던 case 3, 4, 7, 8번이 앙상블 모델에서는 수렴하는 결과를 보여주었다. 반면에 case 2의 앙상블 모델은 수렴하지 못한 결과를 보여주는데 이는 feature encoding의 분리에서 다소 작은 특성으로 분리되어 그 정확도가 떨어지는 것으로 판단된다. 나머지 모델의 경우, 안정적으로 loss와 accuracy가 수렴하는 결과를 보였고, 특히 모델 학습의 결과보다 모델 검증에서의 결과가 좋은 것은, 앞선 모델에 비해 학습데이터 과적합되지 않고, 해당 영상에 대한 적절한 분류기를 생성했기 때문이라고 판단할 수 있다. case E4와

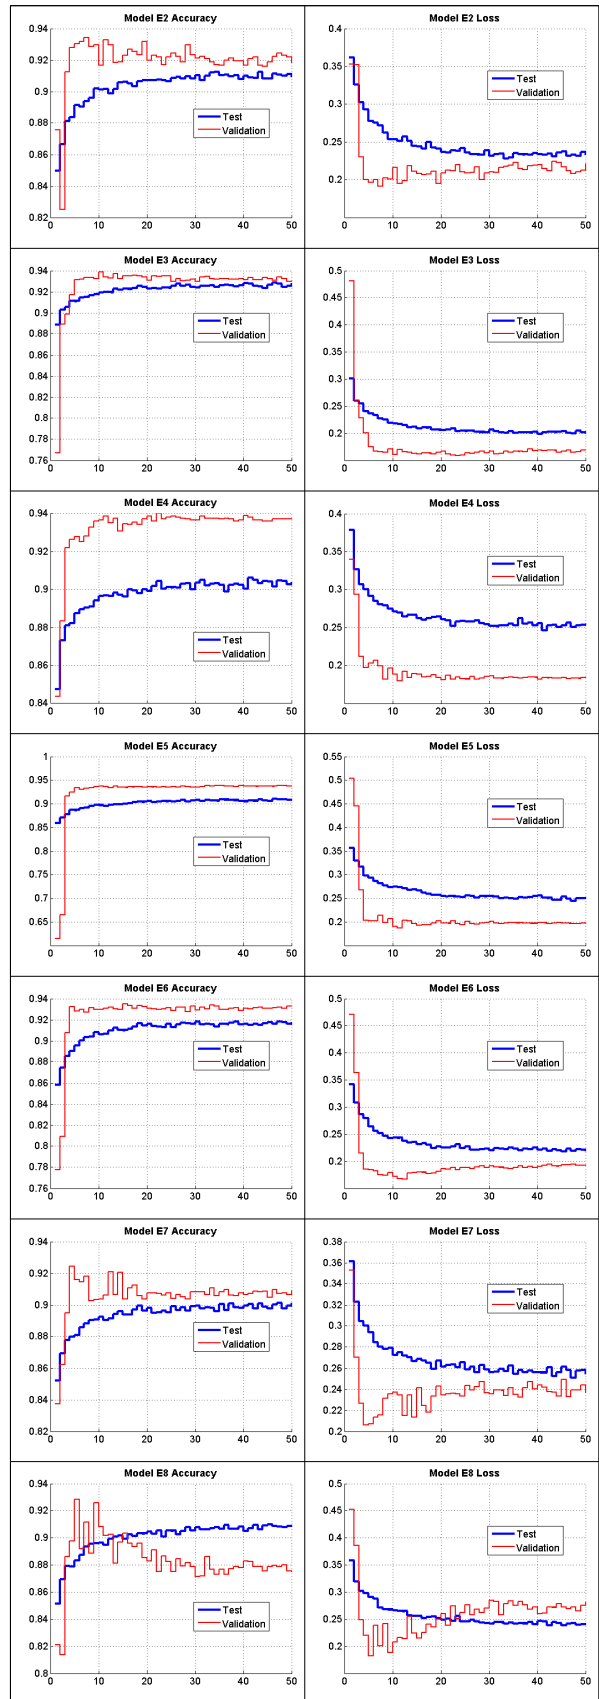


Fig. 8. Accuracy & Cross-Entropy Loss of the Model Ensemble No. 2-8

Table 6. Accuracy & Cross-Entropy Loss of the Ensemble Model No. 2-8

Case	Train set		Validation set	
	Loss	Acc.	Loss	Acc.
E2	0.2331	0.9094	0.2210	0.9184
E3	0.1993	0.9282	0.1694	0.9302
E4	0.2540	0.9038	0.1838	0.9371
E5	0.2499	0.9074	0.1979	0.9381
E6	0.2194	0.9178	0.1924	0.9327
E7	0.2544	0.9011	0.2371	0.9091
E8	0.2405	0.9088	0.2820	0.8752

Table 7. False Count, Precision & Recall Result of the Model

Case	False Count	Precision	Recall
1	132	0.869426752	0.75
2	151	0.858585859	0.700549451
3	228	0.947368421	0.395604396
4	214	0.931034483	0.445054945
5	177	0.901287554	0.576923077
6	149	0.893772894	0.67032967
7	269	0.935779817	0.28021978
8	303	0.942028986	0.178571429
E2	166	0.9125	0.601648352
E3	142	0.875	0.711538462
E4	128	0.84502924	0.793956044
E5	126	0.854166667	0.788461538
E6	137	0.879598662	0.722527473
E7	185	0.904977376	0.549450549
E8	254	0.892857143	0.343406593

E5의 경우, 93% 후반의 accuracy 결과를 보여주었는데, 이는 색상기반 Hue, Saturation, Value와 형상기반의 Area, Direction의 특성이 모델에 잘 반영된 것으로 판단된다.

Table 7은 전체 모델에 대한 검증 시의 오분류 횟수(false count), 정밀도(precision)와 검출율

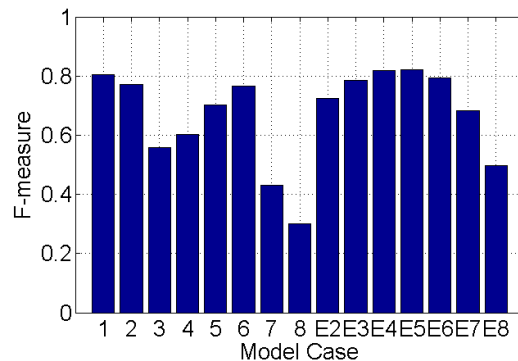


Fig. 9. F-measure of Neural Network Model

(recall)을 나타낸 것이다. 오분류 횟수는 검증 데이터 2,035개 중 잘못 분류한 회수를 나타내는데, 검증 accuracy와 비슷한 경향을 나타내고 있으나, 전반적으로 모델 앙상블의 오검출이 적은 것으로 보인다. precision과 recall은 보통 반비례관계에 있으며, 하나의 결과가 좋은 것보다는 두 값이 적정수준에 위치하는 것이 그 성능이 좋다고 판단할 수 있다. 오검출율이 높은 case 3과 case 8번의 경우, precision이 94%이상의 결과를 보여주지만 recall의 경우 각각 약 40%, 18% 상당히 불안정한 모델로 판단할 수 있다. 반면에 case E4와 case E5의 경우, precision의 값은 중간정도이지만 recall의 경우 가장 좋은 결과를 보여주고 있어 학습데이터의 특성을 잘 반영한 안정적인 모델로 판단할 수 있다. 이러한 결과는 Fig. 9의 precision-recall의 조화평균으로 나타낸 성능 지표인 F-measure에서도 나타난다. F-measure값이 case E4과 case E5에서 각각 0.8187과 0.82로 나타났고, 상대적으로 오검출 횟수가 많았던 case 7, case 8이 각각 0.4313, 0.3002로 가장 낮은 결과를 보여주었다.

IV. 결 론

본 논문에서는 우주파편 능동제거를 수행하기 위해 영상기반 추적시스템에 적용가능한 안정적인 인식모델에 대한 연구를 수행하였다.

제안된 방법은 기존에 영상기반 우주물체 추적에서 적용하지 않았던 심층신경망을 적용하여 기존보다 안정적인 인식성능을 나타내고자 하였다. 또한, 우주환경을 모사한 테스트베드에서 위성의 움직임과 고려하여 우주환경에서 조명 입사각과 카메라 방향각에 따른 영향을 반영한 초소형위성의 영상을 활용하였다. KARICAT 영상 센

서로부터 영상내의 목표물체에 대한 특징벡터를 생성하였고, 이를 활용한 학습을 수행하였다. 학습은 feature encoding의 특성을 반영할 수 있도록 학습모델을 구성하였고, 그 결과 90%내외의 정확도를 보여주었다. 하지만 feature encoding을 나누지 않고 단일 데이터 형태로 학습 경우 93%의 정확도를 넘는 등 학습모델이 데이터의 특성을 제대로 반영하지 못하는 결과를 보여주었으며, 이는 back-propagation중에 소수 feature에 대한 반영이 이루어지지 않아 각 노드의 weight가 적절하지 못하게 업데이트 된 것으로 사료된다. 이를 해결하기 위해 feature encoding에 대한 각각의 모델을 생성하고, 각 모델을 합치는 모델 앙상블을 적용하였다. 모델 앙상블의 경우, 전반적으로 단일 모델을 활용한 경우보다 더 높은 정확도 성능을 보여주었으며, 특히, precision과 recall의 측면에서도 색상과 형태 범주로 나눈 경우 가장 좋은 성능을 확인할 수 있었다.

향후에는 합성곱 신경망 등 보다 향상된 기법을 활용하여 그 성능을 향상시키는 것을 목표로 하고 있으며, 또한, 초소형 그래픽장치에 적용하여 실제 KARICAT 영상 알고리즘에 대한 테스트를 수행하고자 한다.

후 기

본 논문은 '초소형위성을 이용한 미래 우주탐사 핵심기술 개발' 연구과제의 일부로써 수행되었으며, 이에 한국항공우주연구원의 지원에 감사드립니다.

References

- 1) "ESA BR-336 Space Debris: The ESA Approach", ESA Brochures, Apr. 2017.
- 2) Seong, J. D., Kim, H. D. Lim, S. M., "An Analysis of three-dimensional collision probability according to approaching objects to the KOMPSAT series", *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 41, No. 2, 2013, pp. 156-168.
- 3) Seong, J. D., Kim, H. D. Choi, H. Y., "A Study of the Disposal Maneuver Planning for LEO satellite", *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 44, No. 4, 2016, pp. 352-362.

- 4) J.C. Liou and N.L. Johnshon, "Risks in space from orbiting debris", *Science*, 311(5795): pp.340-341, January, 2006.
- 5) Kim, H. D., Kim, M. K., "Recent Status on Active Space Debris Removal Technologies", *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 43, No. 9, 2015, pp. 845-857.
- 6) Krizhevsky, A., Sutskever, I., and Hinton, G., "Imagenet classification with deep convolutional neural networks", *In Advances in Neural Information Processing Systems(NIPS)*, 25, 2012, pp. 1106-1114
- 7) Girshick, R., Donahue, J., Darrell, T., Malik, J., "Rich feature hierarchies for accurate object detection and semantic segmentation", *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, Columbus, OH, 2014, pp. 580-587
- 8) Szegedy, C., Toshev, A., and Erhan, D., "Deep neural network for object detection", *In Advances in Neural Information Processing Systems(NIPS)*, 26, 2013, pp. 2553-2561
- 9) Zhao, S. P., and Khorasani, K., "A Recurrent Neural Network Based Fault Diagnosis Scheme for a Satellite", *Proceedings of the 33rd Annual Conference of the IEEE Industrial Electronics Society(IECON)*, Taipei, Taiwan, Nov. 5-8, 2007.
- 10) Kim, J. H., Lee, D. W., Cho, K. R., Min, C. O., Cho, S. J., "Trajectory Optimization and the Control of a Re-entry Vehicle during TAEM Phase using Artificial Neural Network", *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 37, No. 4, 2009, pp. 350-358.
- 11) Chen, X., Xiang, S., Liu, C. L., and Pan, C. H., " Vehicle Detection in Satellite Images by Hybrid Deep Convolutional Neural Networks", *IEEE Geoscience and Remote Sensing Letters*, Vol. 11, No. 10, Oct, 2014, pp. 1797-1801
- 12) Längkvist, M., Kiselev, A., Alirezaie, M. and Loutfi, A., "Classification and Segmentation of Satellite Orthoimagery Using Convolutional Neural Networks", *Remote Sensing*, Vol. 8, No. 4, 2016, pp. 329-349
- 13) Hu, M. G., Wang, J. F. and Ge, Y.,

“Super-Resolution Reconstruction of Remote Sensing Images Using multifractal Analysis”, *Sensors*, Vol. 9, No. 11, 2009, pp. 8669-8683.

14) Linares, R. and Furfaro, R., “Space Object Classification Using Deep Convolutional Neural Networks”, *Proceedings of the 19th International Conference on Information Fusion(FUSION)*, Jul. 5-8, 2016, pp. 1140-1146

15) Han, P., Du, J. and Fang, M., “Spatial Object Tracking Using an Enhanced Mean Shift Method Based on Perceptual Spatial-Space Generation Model”, *Journal of Applied Mathematics*, Vol. 2013, 2013.

16) Rosso, F., Gallo, Allasia, W., Enrico, L., F., Prinetto, P., Rolfo, D., Trotta, P., Favetto, A., Paleari, M. and Ariano, P., “Stereo vision system for capture and removal of space debris”, *Proceedings of the Design and Architectures for Signal and Image Processing(DASIP)*, Cagliari, Italy, Oct. 2013, pp. 201-207.

17) Opromolla, R., Fasano, G., Rufino, G. and Grassi, M., “A Model-Based 3D Template Matching Technique for Pose Acquisition of an Uncooperative Space Object”, *Sensors*, Vol. 15, 2015, pp. 6360-6382

18) Petit, A., Marchand, E. and Kanani, K.,

“Tracking complex targets for space rendezvous and debris removal applications”, *Proceedings of IEEE/RSJ International conference on Intelligent robots and systems*, Vilamoura, Portugal, Oct. 2012, pp. 4483-4488

19) Choi, W. S., Cho, D. H., Song, H. R., Kim, J. H., Ko, S. J., Kim, H. D., “A 5-DOF Ground Testbed for Developing Rendezvous/Docking Algorithm of a Nano-satellite”, *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 43, No. 12, 2015, pp. 1124-1131.

20) Kim, J. H., Choi, W. S., Cho, D. H., Kim, H. D., Lim, S. M., “Visual Information Based Detection and Tracking Algorithm for Capture of Space Debris using Nano-satellite”, *Proceedings of 29th Workshop on Image Processing and Image Understanding (IPIU 2017)*, 2017.

21) Kim, J. H., Lim, S. M., Kim, H. D., “Depth discontinuity based target space debris candidate ROI Extraction from RGB-D image”, *Proceedings of the 2017 KSAS Spring Conference*, 2017, pp. 518-519

22) Tensorflow, Retrieved Aug. 10, 2017 from <https://www.tensorflow.org>

23) Keras, Retrieved Aug. 10, 2017 from <https://keras.io/>