

전투기용 레이더 기반 SAR 영상 자동표적분류 기능 구조 및 CNN 앙상블 모델을 이용한 표적분류 정확도 향상 방안 연구

임동주^{1),2)*} 송세리³⁾ 박범³⁾

1) 한화시스템(주), 2) 아주대학교 시스템공학과, 3) 아주대학교 산업공학과

Study on the Functional Architecture and Improvement Accuracy for Auto Target Classification on the SAR Image by using CNN Ensemble Model based on the Radar System for the Fighter

Dong Ju Lim^{1),2)*}, Se Ri Song³⁾, Peom Park³⁾

1) *Hanwha Systems*

2) *Ajou University Systems Eng. Dept.*

3) *Ajou University Industrial Eng. Dept.*

Abstract : The fighter pilot uses radar mounted on the fighter to obtain high-resolution SAR (Synthetic Aperture Radar) images for a specific area of distance, and then the pilot visually classifies targets within the image. However, the target configuration captured in the SAR image is relatively small in size, and distortion of that type occurs depending on the depression angle, making it difficult for pilot to classify the type of target. Also, being present with various types of clutters, there should be errors in target classification and pilots should be even worse if tasks such as navigation and situational awareness are carried out simultaneously. In this paper, the concept of operation and functional structure of radar system for fighter jets were presented to transfer the SAR image target classification task of fighter pilots to radar system, and

Received: April 28, 2020 / **Revised:** May 27, 2020 / **Accepted:** June 11, 2020

* 교신저자 : Dong Ju Lim, dongju.lim@hanwha.com

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

the method of target classification with high accuracy was studied using the CNN ensemble model to archive higher classification accuracy than single CNN model.

Key Words : Auto Target Recognition, SAR, Radar, CNN

1. 서론

전투기 조종사는 공대지 임무 수행을 위해 전투기에 탑재된 레이다를 이용하여 원거리 특정 지역에 대한 고해상도 SAR(Synthetic Aperture Radar) 영상을 획득한 후 조종사가 육안으로 영상 내 표적을 구분하는 업무를 수행하고 있다.

하지만 SAR 영상 내 촬영된 표적형상은 크기가 화면 크기 대비 매우 작고, 빔 방사 각도에 따라 형태 왜곡이 발생하거나, 여러 종류의 클러터와 함께 존재하기 때문에, 육안으로 표적을 분류하는 데 오류가 있을 수 있다. 또한, 조종사가 항법, 상황인식, 교전 등의 업무를 동시에 수행하게 될 경우, 표적 분류 정확도는 더욱 낮아질 수 있다.

이 문제를 해결하기 위하여 SAR 영상 내 표적을 자동으로 인식하고 분류하는 방법(Auto Target Recognition, 이하 ATR)이 다양하게 연구되고 있으며[1], 최근에는 이미지 인식 및 분류 성능이 뛰어난 컨볼루션형 뉴럴 네트워크 (Convolutional Neural Network, 이하 CNN)을 이용한 표적분류를 수행하는 방법이 많이 연구되고 있다.

본 논문에서는 전투기 조종사의 SAR 영상 표적 식별 임무를 자동으로 수행할 수 있는 전투기용 레이다 시스템의 기능 구조를 제시하고, CNN 앙상블 모델을 이용하여 표적분류 정확도를 향상하는 방안을 연구하였다.

2. 본론

2.1 전투기용 레이다의 SAR 영상기반 표적인식 기능 운용개념

전투기용 레이다의 SAR 영상 기반 표적 자동분

류 기능의 목적은 SAR 영상 내 표적을 자동으로 분류하고 그 결과를 조종사가 인지하기 쉬운 시각적 정보로 제공하는 것으로 운용개념은 그림 1과 같다.

이를 위한 주요 세부기능은 SAR 영상 내에 표적 탐지(Detection), 표적 탐지 영역에서 표적과 클러터 변별(Discrimination), 그리고 변별된 표적의 종류를 식별하는 분류(Classification)로 구성된다[1].



[Figure 1] Concept of operation for auto target recognition based on SAR image by using radar equipped on fighter jets

2.2 표적 자동인식 기능에 따른 레이다 내/외부 연동 및 기능흐름


전투기용 레이다는 기존에 수행하는 SAR 영상 생성 기능을 수행하여 표적위치의 SAR 영상과 그 영상의 속성정보 획득하여 자동표적인식 처리기능에 입력한다. SAR 영상은 표적 및 클러터의 반사신호를 처리한 결과 영상이며, 자동표적인식 수행시 표적이 존재하는 관심영역 발체 및 표적 분류처리기의 입력크기에 부합하도록 입력영상을 처리한다. 자동표적인식 처리기능은 뉴럴 네트워크 기반 표적 분류처리 기능을 통해 획득한 SAR 영상내 표적의 종류를 식별하고 그 결과를 출력한다. 자동표적인식 수행 결과는 데이터 처리기능으로 입력되어 획득한 SAR 영상에 문자형태로 중첩하여 임무컴퓨터로 전송되며, 다기능전시기(MFD)를 통해 조종사에게 시

각적으로 제공한다. 상기 기능흐름에 대한 시스템 컨텍스트 다이어그램과 활동 다이어그램(IDEF0)은 그림 4 및 5와 같이 정의하였다.

표적일지라도, 이 내림각에 따라 표적의 크기, 밝기와 같은 표적의 형상이 그림 3과 같이 달라지는 특징을 갖는다[3].


2.3 SAR 영상내 표적형상의 특징

전투기용 레이더를 이용한 SAR 영상은 방사된 RF 신호가 목표물 또는 클러터에 반사되어 돌아오는 신호를 처리하여 만든 이미지이다. SAR 영상 형성을 위한 RF 신호 송/수신 시간에 따라 영상 해상도가 결정되며, 레이더(센서)와 표적과의 내림각에 따라 표적 형상이 변하게 된다. 이때 레이더(센서)와 표적(Target) 사이의 기하학적 관계는 그림 2와 같다[2].



[Figure 2] Definition of some common radar imaging terms

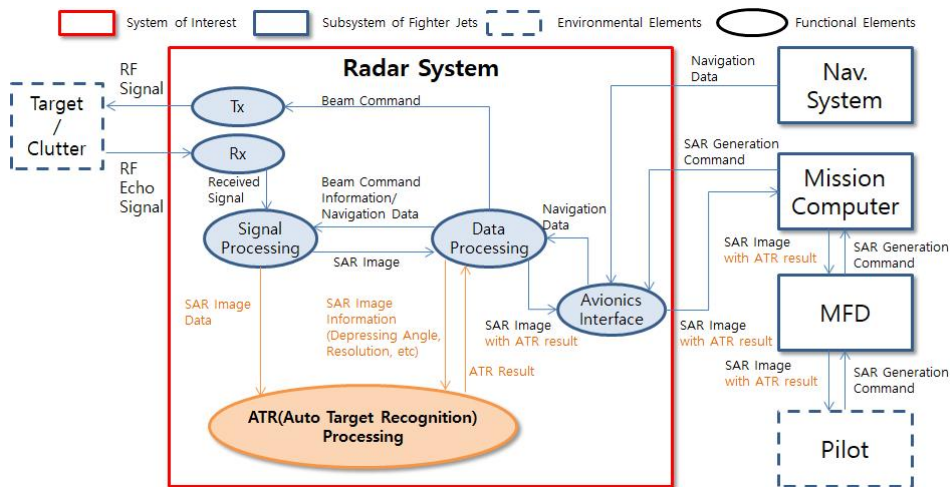
내림각(Depression Angle)은 레이더와 표적까지 이루는 고각방향의 각도로, SAR 영상을 생성할 때의 항법정보 및 자세정보와 빔 조향각도를 이용하여 계산되는 값이다. SAR 영상내 표적은 동일한



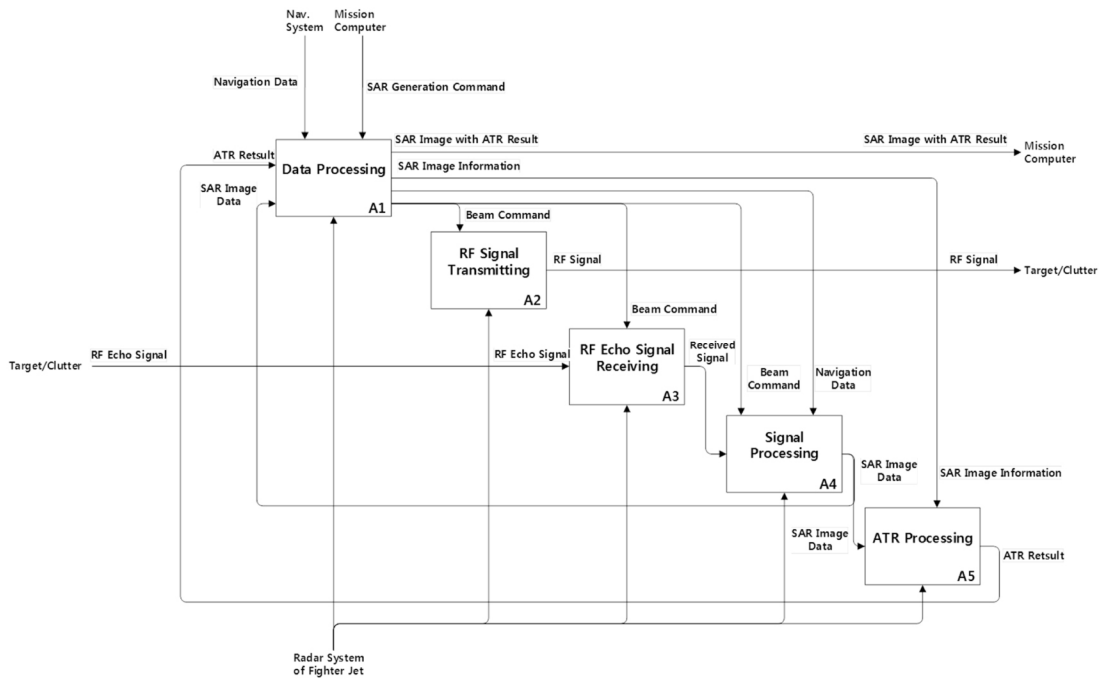
[Figure 3] Example of target image difference between 15° and 45° of depression angle from MSTAR data set

2.4 표적 분류 처리

SAR 이미지는 전자기장이 반사되는 신호를 처리한 영상으로, 육안 또는 광학 이미지와 유사하지 않아 이를 해석하기 위해 숙달된 전문가가 필요하며, 표적을 정확히 분류하는 데에는 많은 시간이 필요하며 매우 어려운 일이다[4]. 특히, 조종을 우선 수



[Figure 4] System context diagram of auto target recognition based on SAR image by using radar equipped on fighter jets



[Figure 5] Activity Diagram of auto target recognition based on SAR image by using radar equipped on fighter jets

행해야 하는 전투기 조종사가 수동으로 수행하는 표적 분류의 정확도를 기대하기 어렵다.


이를 해결하기 위하여 영상 인식 및 이미지 분류 분야에서 좋은 성능을 보이는 CNN 모델을 본 연구에 적용하였다. CNN 모델은 이미지의 공간정보를 유지하면서 이미지의 특징을 추출하고 이를 학습시켜 이미지를 분류하는 모델로 SAR 영상내 표적 자동분류 문제에 다양하게 적용되고 있다[5~9].

SAR 표적영상은 레이더를 탑재하여 실제 비행을 통해 획득해야 하므로, 이에 따른 시간과 비용이 많이 소모되어 충분한 학습데이터를 확보하는 것이 제한된다. 이를 단일 CNN 모델 학습에 사용할 경우, 과적합(Over-fitting) 문제가 발생할 수 있고, 학습되지 않은 이미지 테스트시 분류 정확도가 크게 떨어질 수 있다.

이 문제의 해결을 위해, 학습데이터에 대한 증강(Data augmentation)을 통해 부족한 학습데이터를 늘리고, 여러 개의 CNN 모델을 연결시키는 앙상블(Ensemble)기법을 이용하여 정확도를 향상시켰다.

(1) 제안 모델

첫 번째로 SAR 영상 이미지 데이터를 수집 후 이를 전처리 과정을 통하여 CNN의 모델의 입력데이터로 생성한다. 두 번째로 데이터 증강을 통하여 훈련 데이터에 대한 과적합을 방지한다. 세 번째로 단일 모델보다 향상된 정확성을 위해서 앙상블 모델을 그림 6과 같이 구성한다.



[Figure 6] Target classification proposal model

(2) 실험데이터

실험은 전투기용 레이더와 같은 X대역을 사용한 MSTAR 데이터 세트를 이용하였다. MSTAR 데이터 세트는 다양한 표적의 SAR 영상정보와 표적 종류 및 내림각에 대한 정보를 포함한다. [3] 실험에 사용된 데이터의 레이블과 이미지 수는 표 1과 같

으며, 학습 데이터와 테스트 데이터의 비율은 8:2로 구분하였다.

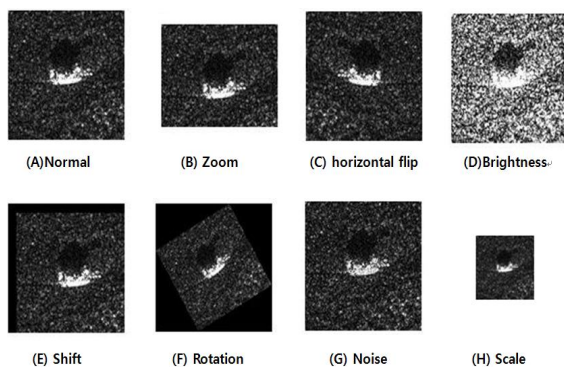
<Table 1> MSTAR data set image configuration

표적 종류 (레이블)	내림각(15도) 이미지 수	내림각(17도) 이미지 수
BTR60	235	195
2S1	299	274
BRDM_2	298	274
D7	299	274
T62	299	273
ZIL131	299	274
ZSU_23_4	299	274
합계	2,028	1,838

(3) 전처리 및 데이터 증강

전처리 단계는 CNN 모델 학습을 위해 이미지 크기를 128 x 128 pixel로 추출한 후, pixel 밝기 정도의 따라 0~255까지 이루어진 2차원 배열을 1차원으로 변환 및 정규화(0~1)를 거친 값과 표 1의 표적 종류(레이블)를 활용하여 CNN 모델의 학습 및 테스트 데이터를 생성한다.

과적합 문제를 해결하기 위해 그림 7과 같이 밝기 변화, 노이즈 추가, 뒤집기 및 이미지 스케일링과 같은 방법을 이용하여 입력 데이터를 증강한 후 앙상블로 구성된 다수의 CNN 모델을 학습시킨다.



[Figure 7] Example of image data argumentation

(4) 학습 모델

다수의 CNN 모델에서 출력된 예측 값을 결합하여 다수의 모델을 학습하는 앙상블 기법은 분류 성

능을 향상시키기 위한 방법 중 하나이다. 본 논문에서는 앙상블 기법 중의 하나인 boosting을 이용하였다. Boosting은 순차적인 weak learner들을 여러 개 결합하여 분류 성능을 높이는 방법으로, 바로 직전의 weak learner의 에러를 지속적으로 갱신하고, 이를 현재의 weak learner에 이를 적용함으로써 정확도를 높이기 때문에, 단일 CNN 모델을 이용하는 것보다 에러율이 적다[10].

앙상블 구성은 서로 다른 구조의 모델을 사용하거나, 유사한 구조의 모델의 가중치 초기화(Weight initialization), 최적화(Optimizer), 학습률(Learning rate) 등을 다르게 설정하고 훈련시킬 수 있으나, 본 논문에서는 서로 다른 3가지 모델을 구성하고 위 파라미터는 동일하게 구성하여 단일 CNN 모델의 정확도를 비교하였다. 각 모델에 예측확률을 병합하여 앙상블 모델에서 최종 MSTAR 데이터 세트의 표적 종류를 예측한다.

(5) 실험 구성 및 결과

실험을 위한 3가지 CNN 모델의 필터와 레이어, 활성화 함수의 구조는 표 2와 같으며, CNN 앙상블 모델 구현 도구는 Python 언어기반 Google Colab과 TensorFlow 및 Keras 함수를 주로 사용했다.

해당 모델들의 성능 평가를 위한 loss와 accuracy는 학습 횟수(Epoch)가 증가함에 따라 그림 8, 9, 10


<Table 2> CNN MODEL configuration

MODEL1		
Layer	Layer Type	Description
1	Input Layer	128 x 128
2	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
3	Convolutional Layer	3 × 3 conv. 64 filter, ReLU
4	Pooling	3×3 max-pooling, stride2
5	Drop Out	50%
6	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
7	Convolutional Layer	3 × 3 conv. 64 filter, ReLU
8	Pooling	3×3max-poolingstride2
9	Drop Out	50%
10	Fully Connected Layer	128 output, ReLU
11	Drop Out	25%
12	Fully Connected Layer	Softmax, Number of class


<Table 2> CNN MODEL configuration (Continued)

MODEL2		
Layer	Layer Type	Description
1	Input Layer	128 x 128
2	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
3	Convolutional Layer	3 × 3 conv. 64 filter, ReLU
4	Pooling	3×3 max-pooling, stride2
5	Drop Out	50%
6	Fully Connected Layer	128 output, ReLU
7	Drop Out	25%
8	Fully Connected Layer	Softmax, Number of class

MODEL3		
Layer	Layer Type	Description
1	Input Layer	128 x 128
2	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
3	Pooling	3×3 max-pooling, stride2
4	Drop Out	50%
5	Input Layer	128 x 128
6	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
7	Pooling	3×3 max-pooling, stride2
8	Drop Out	50%
9	Input Layer	128 x 128
10	Convolutional Layer	3 × 3 conv. 32 filter, ReLU
11	Pooling	Global pooling
12	Fully Connected Layer	Softmax, Number of class




[Figure 8] Accuracy and loss rate curve of CNN Model 1



[Figure 9] Accuracy and loss rate curve of CNN Model 2

과 같이 분류 정확도가 높아짐을 확인했다. 특히 세 CNN 모델 모두 훈련 데이터 보다 테스트 데이터 정확도가 대체로 높은 것으로 보아, 데이터 증강을



[Figure 10] Accuracy and loss rate curve of CNN Model 3

했기 때문에 과적합되지 않았음을 확인할 수 있다. 훈련시킨 모델들을 앙상블로 구성했을 때의 분류 정확도는 표 3과 같다. 테스트 데이터는 각 모델에서 쓰인 것과 동일하며 5회 실시하여 평균으로 정확도를 산정하였다. 그 결과, 앙상블을 이용한 테스트 정확도가 99.16%로 단일 CNN 모델 각각의 테스트 정확도보다 약 1.5~5.7 %p 높음을 확인할 수 있다.

<Table 3> Single CNN Model vs Ensemble Model Test Result

Model	epoch	train loss [%]	train 정확도 [%]	test loss [%]	test 정확도 [%]	
단일 모델	1	1000	0.36	91.23	0.14	97.67
	2	1000	0.68	82.67	0.21	93.45
	3	1000	0.39	90.56	0.19	95.31
Ensemble	-	-	-	0.12	99.16	

3. 결론

본 논문은 전투기용 레이더에 적용하기 위한 SAR 영상 기반 표적 자동인식기능 운용개념 및 기능구조를 설정하고, SAR영상 표적 자동 분류 기능의 정확도를 향상할 수 있는 방안에 대하여 연구하였다. 이를 위하여 전투기용 레이더의 임무 및 운용개념을 도출하고 이에 따른 기능 및 그들 사이의 연관관계를 정의하였으며, 앙상블 CNN 모델을 이용하여 SAR 표적영상의 분류 정확도를 높일 수 있는 방안을 제시하였다. 이 기능을 적용할 경우 조종사의 표

적식별 업무를 전투기용 레이더 시스템으로 전이할 수 있을 뿐만 아니라, 조종사보다 정확하게 표적을 분류할 수 있을 것으로 기대한다.

References

1. 김경태, SAR 표적 식별 기술, 한국전자과학회지 vol.22, No.6, p84, 2011.
2. Jakob Van Zyl and Yunjin Kim, Synthetic Aperture Radar Polarimetry, NASA, p.5, 2010
3. MSTAR Data Set, <https://www.sdms.afrl.af.mil/>
4. Sizhe Chen, Haipeng Wang, SAR Target Recognition Based on Deep Learning, International Conference on Data Science and Advanced Analytics, 2014.
5. Janette C. Briones, Benjamin Flores, Raul Cruz-Cano, Multi-mode radar target detection and recognition using neural networks, International Journal of Advanced Robotics Systems, 2012.
6. Li Wang, Xueru Bai, Feng Zhou, SAR ATR of Ground Vehicles Based on ESENet, Remote Sensing, 2019.
7. Sizhe Chen, Feng Xu, Ya-Qui Jin, Target Classification Using the Deep Convolutional Networks for SAR Images, IEEE Transaction on Geoscience and Remote Sensing, vol.54, No.8, 2016.
8. Shuo Yang, Li-Fang Chen, Tao Yan, Yun-Hao Zhao, Ye-Jia Fan., An Ensemble Classification Algorithm for CNN on Adaboost, IEEE/ACIS 16th International Conference on Computer and Information Science(ICIS), 2017.
9. Yuan Xue, Jifang Pei, Ylin Huang, Jianyu Yang, Yun Zhang, Target Recognition for SAR Images base on Heterogeneous CNN Ensemble, IEEE Radar Conference, 2018.
10. Mohammad Moghimi, Mohammad Saberian, Jian Yang, Li-Kia Li, Nuno Vasconcelos, Serge Belongie, Boosted Convolutional Neural Networks, British Machine Vision Conference(BMVC), 2016.
11. Mark. W. Maier, The Art of System Architecting, CRC Press, 2002.