

적외선 영상에서의 표적과 클러터 구분을 위한 Hybrid Machine Character 기반의 Du-CNN 설계

이주영¹⁾ · 임재완¹⁾ · 백하은¹⁾ · 김춘호²⁾ · 박정수²⁾ · 고은진^{*,1)}

¹⁾ 국방과학연구소 제3기술연구본부

²⁾ 국방과학연구소 제1기술연구본부

A Design of Du-CNN based on the Hybrid Machine Characters to Classify Target and Clutter in The IR Image

Juyoung Lee¹⁾ · Jaewan Lim¹⁾ · Haeun Baek¹⁾ · Chunho Kim²⁾ · Jungsoo Park²⁾ · Eunjin Koh^{*,1)}

¹⁾ *The 3rd Research and Development Institute, Agency for Defense Development, Korea*

²⁾ *The 1st Research and Development Institute, Agency for Defense Development, Korea*

(Received 20 April 2017 / Revised 10 October 2017 / Accepted 27 October 2017)

ABSTRACT

In this paper, we propose a robust duality of CNN(Du-CNN) method which can classify the target and clutter in coastal environment for IR Imaging Sensor. In coastal environment, there are various clutter that have many similarities with real target due to diverse change of air temperature, water temperature, weather and season. Also, real target have various feature due to the same reason. Thus, the proposed Du-CNN method adopts human's multiple personality utilization and CNN technique to learn and classify target and clutter. This method has an advantage of the real time operation. Experimental results on sampled dataset of real infrared target and clutter demonstrate that the proposed method have better success rate to classify the target and clutter than general CNN method.

Key Words : Infrared Image(적외선 영상), Convolutional Neural Network(합성곱신경망), Target Classification(표적분류), Machine Learning(기계학습), Multiple Personality(다중인격)

1. 서론

적외선 영상센서로 해상에 위치한 표적을 식별하는 문제에 있어서, 해수면 상에서 발생할 수 있는 많은

클러터들의 특징을 파악하고 적절하게 분류해 내는 문제는 표적탐지의 정확도를 높이기 위한 방법 중에서도 매우 중요한 사항이다. 따라서 분류기의 성능을 높이는 것이 요구되나 자원이 제한된 소형 센서 시스템의 실시간성을 고려하면 연산량을 무작정 늘릴 수는 없다. 이러한 이유로 연산량의 증가를 최소화하면서도 정확도를 높이는 것이 최우선적으로 고려되어야

* Corresponding author, E-mail: eikoda@gmail.com

Copyright © The Korea Institute of Military Science and Technology

할 사항이다.

해수면에서의 표적 탐지 알고리즘은 기본적으로 표적과 클러터를 분류하기 위한 방법들을 적용하고 있으며, SURF와, RDL(Robust Dictionary Learning)를 이용한 방법^[12], QFT(Quaternion Fourier Transform)을 이용한 방법^[3] 등 관련된 많은 연구가 진행되어 왔다.

하지만 이러한 방법들은 표적과 클러터가 기온과 수온의 다양한 변화에 따라 유사한 형태를 띠는 등의 상황에서는 제한적이다. 그러므로 본 논문에서는 표적과 클러터 구분 방법에 CNN(Convolutional Neural Network)를 적용하고, 인간의 다중인격 활용방법 기반의 새로운 기계학습 및 판단 방법을 융합하였으며, 이를 통해 연산량을 최소화하면서 성능을 높이는 방법을 실험을 통해 제시하였다.

다사카 히로시 박사의 저서인 ‘사람은 누구나 다중인격^[4]’에 따르면, 자기 안에 있는 복수의 인격을 주어진 상황이나 입장에 따라 의식적으로 교체하면서 이를 드러내고 대처하면 자연스럽게 다양한 재능이 생기고, 숨은 가능성을 발견할 수 있다고 한다. 이러한 개념을 기계학습에 적용시키면, 복수의 인격으로 학습된 기계가 주어진 상황이나 입장에 따라 의식적으로 교체하면서 대처하는 것이 가능하다. 그러므로 Deep Learning으로 풀어야 할 다양한 과제에 이 방법을 적용하면, 연산량 증가는 최소화하고 기계의 숨은 가능성을 발견하여 성공률을 높일 수 있을 것이다.

본 논문에서는 기계학습에 다양한 시각을 적용시키는 일종의 기계적 다중인격을 도입하는 개념을 적용함으로써 표적과 클러터를 구분하는 새로운 방법을 제안한다.

2장에서는 기존의 CNN을 이용해서 표적과 클러터를 학습한 내용을 설명하고, 3장에서는 Du-CNN을 이용한 표적과 클러터 구분방법을 제안한 후, 4장에서 제안한 방법을 이용하여 실험한 결과를 제시한다.

2. CNN을 이용한 표적과 클러터 학습

CNN(Convolutional Neural Network)은 입력된 영상에 대해 물체를 인식하는 과정을 인간의 시신경을 모사해서 설계된 기계학습 방법으로, 최근에 영상인식 분야에서 뛰어난 성능을 나타내는 것으로 보고되고 있다^[5]. 이것은 GPU 및 컴퓨터 시스템 성능의 발달로 인해 복잡하고 다수의 층으로 이루어진 CNN 구조를

빠른 시간 안에 수행하는 것이 가능하게 되면서 많은 영상인식 과제들을 해결하는데 적합하기 때문이다^[7].

표적과 클러터를 구분하는 방법에도 CNN의 적용이 가능하며, 기존의 연구들이 보여주듯이 다수의 층으로 이루어진 CNN 구조를 적용한다면 정확도를 높이는 데 유리할 것이다. 하지만 표적을 실시간으로 탐지해야 하는 소형 센서의 제한된 Processor 성능을 고려했을 때, CNN층을 늘리는 것과 실시간 연산량 사이에는 trade-off가 존재한다. 따라서 본 논문에서는 영상 획득 시험을 통해서 확보한 표적 및 클러터 영상들을 CNN을 이용해서 학습시키기는 하지만, 소형 센서의 제한된 연산 성능을 고려하여 CNN의 층을 최대한 늘리지 않으면서 정확도를 개선할 수 있는 방법을 제안한다.

본 논문에서 CNN 구조는 2개의 convolution층, 2개의 pooling층을 적용했다. CNN 구조만을 이용해서 10만 번의 학습을 수행한 결과, 성공률은 약 76.3 %로서 너무 낮았기 때문에 마지막 pooling층과 출력노드 사이에 추가로 전결합 2층을 연결하였다. 앞서도 설명했듯이 CNN 구조를 단순한 2층으로 설계한 이유는, 표적과 클러터를 실시간으로 구분할 소형 센서 Processor의 연산량을 고려했기 때문이다. 컨볼루션 필터는 5×5 크기를 사용하고, 6가지와 12가지의 필터를 사용한다. 각각의 필터 및 바이어스는 0~1 사이의 임의의 수로 초기화를 수행한다. 28×28 영상이 CNN 입력으로 들어오면 첫 번째 컨볼루션 층에서는 5×5 필터 6개를 이용해서 컨볼루션 연산을 수행하고, 24×24×6개의 영상이 다음 pooling층으로 출력된다. pooling층에서는 2×2 영역에 대해 최대(max)값을 취해서 12×12×6의 영상을 출력한다. 두 번째 컨볼루션 층에서 12개의 필터로 연산을 수행한 후에는 8×8×12의 영상이 출력되며, 두 번째 pooling층에서 다시 2×2 영역에 대해 최대(max)값을 취해서 4×4×12의 영상을 출력한다. pooling층 다음에는 2개의 전결합층을 통해 출력 층으로 activation된다. 각 layer의 activation 함수는 sigmoid 함수를 사용했다.

2.1 label 10 으로 분류한 CNN의 학습

위에서 언급한 CNN구조를 이용해서 표적을 7가지로 분류하고, 클러터를 3가지로 분류한 총 10가지 레이블로 학습을 시켰다. 표적은 진입, 좌에서 우로 이동, 우에서 좌로 이동, 퇴각, 정지, 역상정지, 역상이동 이렇게 7가지로 분류되며, 클러터는 햇빛반사, 역상향적, 자연현상 이렇게 3가지로 분류된다. 분류한 레이블 및 대표적인 영상을 나타내면 Table 1과 같다.

Table 1. IR image divided into 10 label

Label	Name	Class	IR Image
1	Approaching Target	Target	
2	Moving left Target	Target	
3	Moving away Target	Target	
4	Moving right Target	Target	
5	Still Target	Target	
6	Negative Target	Target	
7	Negative Moving Target	Target	
8	Sun glint	Clutter	
9	Negative wake	Clutter	
10	Natural state	Clutter	

그리고 학습한 CNN구조를 테스트하기 위한 영상은 28×28 크기의 53,119개 영상을 이용했다. 테스트한 영상 중 대표적인 클러터와 표적 영상은 Fig. 1과 같다.




Fig. 1. Test dataset about IR image

또한 다양한 해상환경 영상중 대표적인 표적과 클러터 영상이라 할 수 있는 10,000개의 28×28 영상들을 정리해서 학습을 위한 데이터로 사용하였으며, 필터의 가중치 및 바이어스의 최적화를 위해 같은 학습을 10번 반복했다. 그리고 행렬벡터 연산을 간략화하기 위해, 50개의 배치리스트를 동시에 계산했다. 전체 구조는 Fig. 2와 같으며, 학습결과에 대한 loss-function은 Fig. 3과 같다.




Fig. 2. CNN structure of 10 label

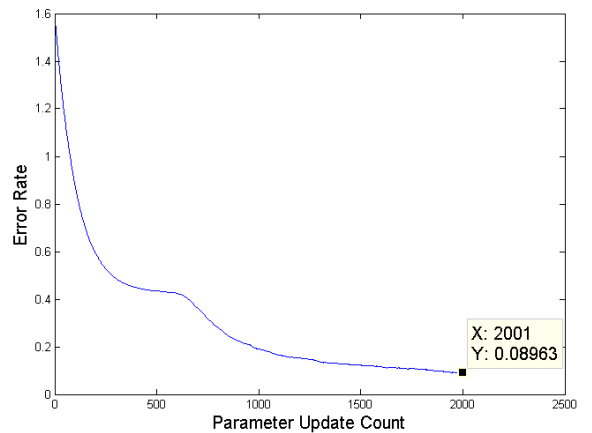


Fig. 3. Loss-function of 10 label

Fig. 3의 y축은 Error Rate로, 학습데이터의 목표출력과 신경망 출력과의 차이를 나타낸다. 수식으로는 다음과 같이 간단히 나타낼 수 있다.

$$E = \frac{1}{2} \| y(x) - a \|^2 \quad (1)$$

여기서 $y(x)$ 는 학습데이터의 목표출력이고, a 는 신경망의 출력이며, E 는 Error Rate 이다.

Fig. 3의 x축은 신경망의 파라미터 업데이트 횟수이

다. 50개의 배치로 약 2,000번의 업데이트를 수행했다. 수행한 후의 error rate는 0.08963 정도였다. 실험결과, 총 53,119개 테스트 영상 중 5,984개 영상에 대해 잘못된 판단을 했고, 성공률은 약 88.73 %이다. 업데이트 횟수를 더 늘려서 실험을 했지만 성공률이 개선되지는 않았으므로, 2,000번의 파라미터 업데이트 후 학습을 중단했다.

2.2 label 3으로 분류한 CNN의 학습

다음실험으로는, 학습 label을 백상표적, 역상표적, 클러터 이렇게 세 가지로 분류하고 나머지 CNN구조는 동일하게 유지한 상태로 학습을 시켰다. 전체 구조는 Fig. 4와 같으며, 학습결과에 대한 loss-function은 Fig. 5와 같다.




Fig. 4. CNN structure of 3 label

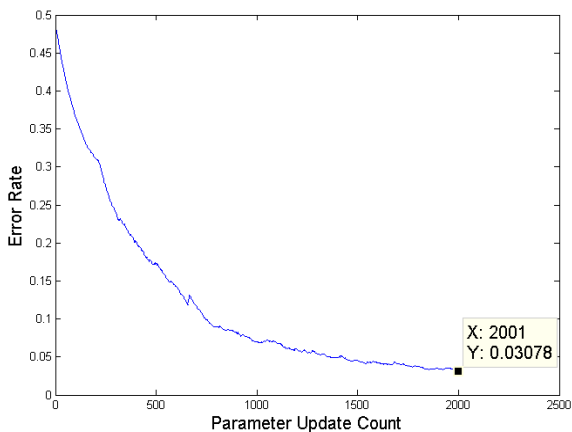


Fig. 5. Loss-function of 3 label

50개의 배치로 약 2,000번의 업데이트를 수행한 후의 error rate는 0.03078 정도였다. 실험결과, 총 53,119개 테스트 영상 중 5,272개 영상에 대해서 잘못된 판

단을 했으며, 성공률은 약 90.08 %으로 10개 label로 학습했을 때보다 1.35 % 가량 증가했다. 업데이트 횟수를 더 늘려서 실험을 했지만 성공률이 개선되지는 않았으므로, 2,000번의 파라미터 업데이트 후 학습을 중단했다.

2.3 CNN층을 추가한 후의 학습

이번에는 앞서와 같이 label을 세 가지로 분류하고, CNN구조를 한층 더 추가한 후 필터 개수를 늘린 상태로 학습을 시켜 보았다. 전체 구조는 Fig. 6과 같으며, 학습결과에 대한 loss-function은 Fig. 7과 같다.




Fig. 6. CNN structure after a CNN layer added




Fig. 7. Loss-function after a CNN layer added

50개의 배치로 약 2,000번의 파라미터 업데이트 후, 업데이트 횟수를 더 늘려서 실험한 결과 성공률이 개선되었기 때문에, 총 6,000번의 업데이트를 수행했다. 업데이트를 수행한 후의 error rate는 0.02679 정도였다. 실험결과, 총 53,119개 테스트 영상 중 4,579개 영상에 대해서 잘못된 판단을 했으며, 성공률은 약 91.38 %으로 CNN층을 추가한 결과 성능이 개선됨을 확인했다.

2.4 CNN 학습결과와의 비교

여기서 주목할 점은, 표적과 클러터의 구분이라는 같은 문제에 대해서 어떻게 label을 나누어서 CNN에 학습시키느냐에 따라 같은 테스트 영상에 대해서도 서로 다른 판단을 한다는 특징이다.

Table 2는 테스트 데이터 중 세 개의 햇빛반사 클러터 영상에 대해서 서로 다르게 판단한 결과를 나타내고 있다. Table 안의 숫자는, 주어진 입력영상이 각 label에 속할 0~1 사이 확률 중 최댓값을 의미한다. 첫 번째 영상은 label 3으로 나누었을 때와 CNN층을 추가한 경우 클러터로 잘 분류해냈지만, label 10으로 나누었을 경우에는 역상표적으로 잘못 판단했다. 두 번째 영상 역시 label 3으로 나누었을 때와 CNN층을 추가했을 경우에는 클러터로 잘 판단했지만, label 10일 때는 역상표적으로 잘못 판단했다. 세 번째 영상 또한 label 3일 때와 CNN층을 추가한 경우에는 잘 판단했지만, label 10일 때는 역상표적으로 잘못 판단했다.

Table 2. Different classification in clutter image



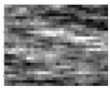
IR Image	3 Label	10 Label	3 Label (+1 CNN)
	Clutter	Target	Clutter
	0.9950	0.6861	0.6388
	Clutter	Target	Clutter
	0.6724	0.6214	0.7951
	Clutter	Target	Clutter
	0.9783	0.5702	0.9907

Table 3. Different classification in target image

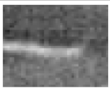
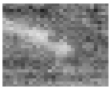
IR Image	3 Label	10 Label	3 Label (+1 CNN)
	Clutter	Target	Clutter
	0.9711	0.1855	0.9535
	Clutter	Target	Clutter
	0.9896	0.4073	0.7921

Table 3은 테스트 데이터 중 두 개의 표적 영상에 대해서, 학습 label수에 따라 서로 다르게 판단한 결과를 나타내고 있다. 첫 번째 영상은 label 10으로 나누

었을 때는 표적으로 잘 분류해냈지만, label 3과 CNN층을 추가했을 경우에는 클러터로 잘못 판단했다. 두 번째 영상도 마찬가지로 label 10으로 나누었을 때만 표적으로 분류해냈다.

3. Du-CNN을 이용한 표적과 클러터 구분

2장에서는 서로 다른 label의 수로 학습한 결과를 각각 확인하였다. Table 2, 3에서와 같이 한가지의 CNN 구조를 이용하면, 같은 영상에 대해서 올바른 판단을 하는 경우도 있는 반면에 잘못된 판단결과를 얻게 될 수도 있다는 것을 알 수 있었다.

이렇게 표적과 클러터의 구분이라는 같은 주제에 대해서 서로 다른 label의 수로 학습한 결과를 잘 이용하면, 인간이 한 가지 주제에 대해 경우에 따라 다양한 시야로 바라보는 특징을 CNN에 적용할 수 있어, 표적과 클러터 구분에 있어서 다양한 시각이 융합된 시너지 효과를 기대할 수 있다. 그리고 서로 다른 label 수로 학습된 CNN 구조는 각각 다르게 학습된 기계의 다중인격이라고 볼 수 있기 때문에 Tao Yang의 논문^[8]에 명시된 것과 같이, 학습된 각각의 특징을 기계의 “machinality”라고 하겠다. 또한 이렇게 다중 “machinality”로 이루어진 CNN 구조의 명칭을 “Duality of CNN”, 줄여서 “Du-CNN”이라 하겠다.

3.1 Du-CNN을 이용한 학습방법

제안하는 Du-CNN을 이용한 학습방법은 아래 Fig. 8과 같다. Du-CNN에서는 10개 label과 3개 label로 학습된 machinality를 사용하였다. 본 논문에서는 Fig. 8의 (a)와 같이 label 10개로 학습된 machinality를 complex machinality(M_c)라 하고, (b)와 같이 label 3개로 학습된 machinality를 simple machinality(M_s)라고 하겠다.

전결합층의 layer 수와 관련해서는 Table 4와 같이 전결합층을 늘려가면서 테스트를 수행했다.

4층 이상 추가 할수록 학습완료 후의 error rate가 증가하고 overfitting이 발생했다. CNN의 층을 늘려서 overfitting을 방지하고 정확도를 높이는 방법도 있겠지만, 1장에서 언급한 것과 같이 실시간으로 동작하는 소형 센서 Processor의 연산량을 고려했을 때, CNN층을 늘리지 않고 Du-CNN 방식을 적용해서 연산량의 증가를 최소화하고 정확도를 높이는 것은 타당한 접근방법이다.

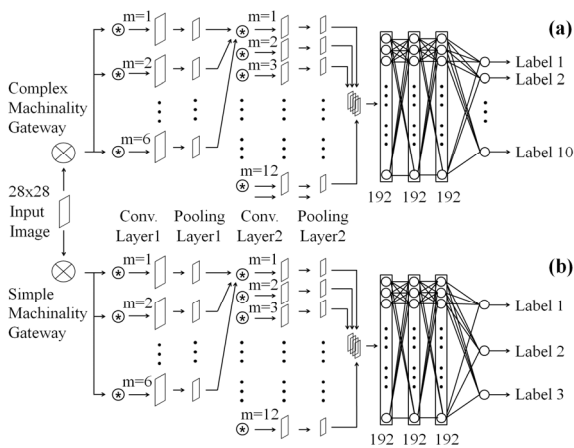


Fig. 8. Learning structure of Du-CNN, (a) complex machinality(M_c), (b) simple machinality(M_s)

Table 4. Loss-function of each layer level

fully-connected layer level	10 Label	3 Label
3		
4		

마지막으로 경우에 따라 어떤 machinality의 판단을 이용하는냐의 문제가 남아있는데, 이는 각 machinality의 특징을 분석하면 알 수 있다. label을 10개로 나누어서 학습한 complex machinality의 경우는 표적과 클러터를 진입하고 있는 표적, 좌에서 우로 이동하는 표적, 퇴각하고 있는 표적, 우에서 좌로 이동하는 표적, 정지해있는 표적, 바다보다 온도가 낮은 역상 정지 표적, 바다보다 온도가 낮은 역상 이동 표적, 햇빛반사에 의한 클러터, 표적이 지나간 항적에 의한 클러터, 자연적으로 발생하는 클러터, 이렇게 10개 label로 다양하게 나누어서 보기 때문에, 역상과 백상으로 이루어진 다양한 영상에 대해서는 비교적 정확한 판단을

했지만, 백상의 클러터 까지도 표적으로 오판단하거나 그 반대의 경우도 발생했다. 53,119개 실험데이터 중에서, complex machinality가 오판단한 5,984개 영상 중 일부 결과는 Table 5와 같다.

Table 5. Result of complex machinality

		IR Image				
Fail (5,984)		Target		Target	0.8722	0.6214
		Target		Target	0.6861	0.6881
		Clutter		Clutter	0.2987	0.2987
		Clutter		Clutter	0.4074	0.7259
		Clutter		Clutter	0.1155	0.4102
		Clutter		Clutter	0.2740	0.7671
		Clutter		Target	0.2709	0.5702

Table 6. Result of simple machinality

		IR Image				
Fail (5,272)		Target		Clutter	0.6385	0.9896
		Clutter		Clutter	0.4988	0.9837
		Clutter		Clutter	0.9977	0.9858
		Clutter		Clutter	0.9267	0.9743
		Clutter		Clutter	0.9838	0.9711
		Clutter		Clutter	0.9896	

반면에 simple machinality는 바다보다 온도가 높은 표적, 바다보다 온도가 낮은 역상 표적, 클러터, 이렇게 3개 label로 단순하게 나누어서 보기 때문에 배경과의 온도차가 큰 영상에 대해서는 비교적 정확한 판단을 했지만, 배경온도 보다 낮은 역상 역상이나 온도차가 크지 않은 영상에 대해서는 오판단하는 경우가 발생했다. 53,119개의 동일한 실험데이터 중에서, simple machinality가 오판단한 5,272개 영상 중 일부는 Table 6과 같다.

3.2 Du-CNN을 이용한 구분 방법

제안하는 Du-CNN을 이용한 구분방법은 10개 label로 나눈 구조의 장점과 3개 label로 나눈 구조의 장점을 모두 이용하는 방법이다. 별도의 탐지 알고리즘을 통해 후보로 포착된 표적이 역상일 때는 다양하게 생각하는 complex machinality가 판단한 결과를 이용하고, 표적이 백상일 때는 단순하게 생각하는 simple machinality가 판단한 결과를 이용한다. 표적후보가 역상인지 백상인지의 판단은 Fig. 9와 같이 표적영역인 tg와 표적을 둘러싼 배경영역인 bg와의 신호세기 차이를 계산해서 판단한다. 이 신호세기 차이를 역상과 백상을 구분하기 위한 threshold로 설정하였으며, tg영역과 bg영역의 픽셀 수는 동일하기 때문에 threshold가 0을 초과하면 백상으로, 0이하이면 역상으로 판단한다. Du-CNN을 이용하는 과정은 수식 (2)와 같다.

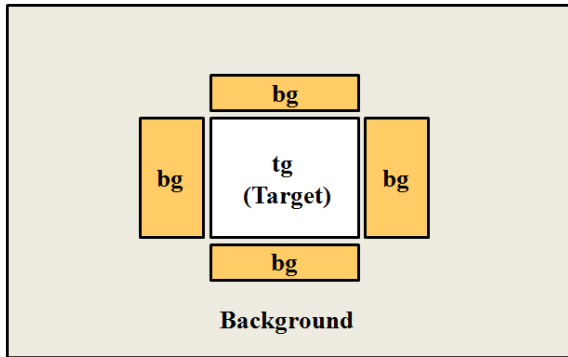


Fig. 9. Target and background area

$$L = Du(I), L \in \{target, clutter\},$$

$$Du(I) = \begin{cases} M_c(I) & \text{if } (\mu_{tg} - \mu_{bg}) \leq 0 \\ M_s(I) & \text{if } (\mu_{tg} - \mu_{bg}) > 0 \end{cases} \quad (2)$$

여기서 L 은 표적과 클러터를 구분하는 최종 결과값이다. Du 는 영상 I 를 입력으로 받아서 표적과 클러터를 구분하는 Du-CNN구조를 나타낸다. 그리고 μ_{tg} 와 μ_{bg} 는 각각 표적영역의 신호세기 평균값과 배경영역의 신호세기 평균값을 의미하는데, μ_{tg} 가 μ_{bg} 보다 작거나 같으면 complex machinality로 학습된 M_c 구조를 이용한다. 반면에 μ_{tg} 가 μ_{bg} 보다 크면, simple machinality로 학습된 M_s 구조를 이용한다.

제안하는 Du-CNN 방법을 이용해서 표적과 클러터를 구분하는 구조는 Fig. 9와 같다. 별도의 탐지 알고리즘을 통해 후보로 포착된 표적은 수식 (1) 및 Fig. 10과 같은 과정을 거쳐서 역상표적인지 백상표적인지 구분된 후, 역상이면 Du-CNN의 complex machinality구조, 백상이면 simple machinality구조가 호출된다. 그리고 2개의 콘볼루션 층, 2개의 풀링층, 3개의 전결합층을 거친 후 최종판단을 한다.

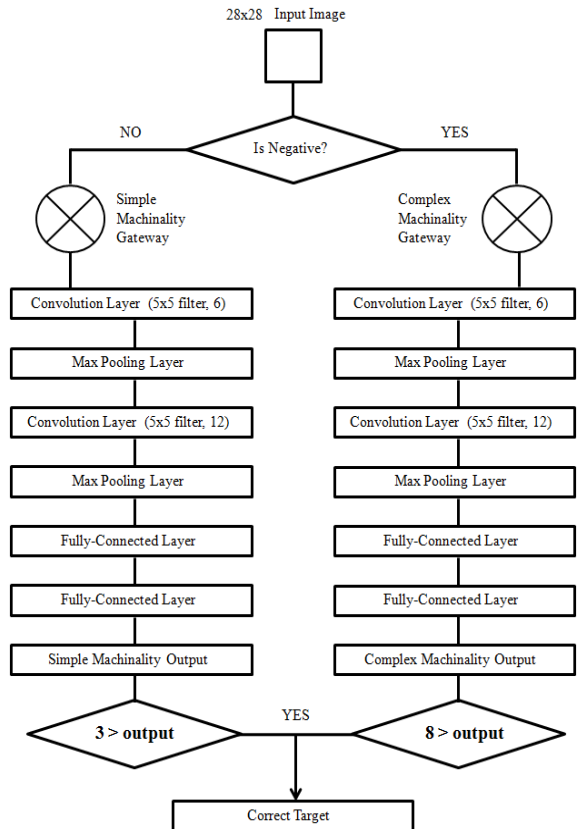


Fig. 10. Classification structure of Du-CNN

4. Du-CNN을 이용한 표적과 클러터 구분 결과

Table 7과 같이, 표적과 클러터를 구분하는데 제안한 Du-CNN구조를 이용하면, 기존의 단일 machinality의 학습내용을 이용하는 것보다 성능이 좋은 것을 알 수 있다. 두 가지의 machinality를 이용한 Du-CNN의 수행 결과, complex machinality만 이용했을 때보다 성공률이 약 3.76 % 증가했고, simple machinality만 이용했을 때보다 약 2.41 % 증가했다.

Table 7. Comparison result of classification















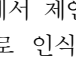

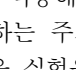
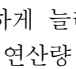
CNN level	FC level	Machinality	Success Rate(%)	For Target	For Clutter
Conv. 2 Pooling. 2	3	complex (10 Label)	88.73	89.93	74.61
Conv. 2 Pooling. 2	3	Simple (3 Label)	90.08	90.45	85.50
Conv. 3 Pooling. 2	3	complex (3 Label)	91.38	93.76	63.57
Conv. 2 Pooling. 2	3	Duality	92.49	92.87	87.91

특히, 표적을 클러터로 인식한 miss alarm은 complex machinality가 4,925개, simple machinality가 4,670개 영상으로 각각의 인식률은 89.93 %, 90.45 % 이었다. 반면, 제안한 Du-CNN구조는 3,485개 표적영상을 클러터로 인식했고, 인식률은 92.87 % 이었다. 또한 클러터를 표적으로 인식한 false alarm은 complex machinality가 1,073개, simple machinality가 613개 영상으로 각각의 인식률은 74.61 %, 85.50 % 이었다. 반면에, 제안한 Du-CNN구조는 511개 클러터영상을 표적으로 인식했고, 인식률은 87.91% 이다.

Table 7의 3번째 실험에서는 CNN의 층을 늘려서 91.38 % 정도까지 성능을 개선했지만, 최대 74.9 ms의 시간이 소요되었다. 반면에 제안한 방법은 CNN의 층을 늘리지 않으면서 43.5 ms의 시간을 소요함과 동시에 92.49 % 정도까지 성능을 더욱 개선시켰다. 따라서 제안한 Du-CNN을 이용하면 실시간으로 동작하는 소형센서의 연산량 증가를 최소화하면서도 정확도를 높일 수 있다는 것을 확인하였다.

53,119개의 동일한 실험데이터 중에서, Du-CNN 방법이 오판단한 3,987개 영상 중 일부는 Table 8과 같다.

Table 8. Result of Du-CNN

	IR Image			
		Target		Clutter
Fail (3,987)		0.6385		0.2987
		Clutter		Clutter
		0.4988		0.9837
		Clutter		Clutter
		0.7259		0.9858
		Clutter		Clutter
		0.4102		0.9743
		Clutter		
		0.9838		

5. 결론

본 논문에서 제안한 Du-CNN 구조는 인간이 다중인격을 스스로 인식하고 효율적으로 관리하는 장점을 기계학습에 적용해본 새로운 방법으로써, 표적과 클러터를 구분하는 주제에 적용했을 때 성능을 높일 수 있다는 것을 실험을 통해 확인하였다. 그리고 CNN의 층을 복잡하게 늘리지 않고 실시간으로 동작하는 소형 센서의 연산량 증가를 최소화하면서 정확도를 높였다는 점에서 Du-CNN의 장점을 찾을 수 있다. 또한 본 주제뿐만 아니라 다양한 영상인식 기술에 다중인격 기계학습을 적용하는 것이 가능하다. 입력받은 영상에 대해 날씨, 주변의 장애물, 고도 등 현재 주어진 상황이나 입장에 따라 의식적으로 두 machinary를 교체하면서 적절하게 대처한다면 더욱 유용한 결과를 얻을 수 있을 것이다. 본 논문에서 제안한 Du-CNN을 시발점으로 다중인격 기계학습 방식을 점차 발전시켜 나간다면, 기계학습의 다각화 및 전문성을 넓혀 나갈 수 있을 것이라 기대한다.

References

[1] H. Zhang, Z. Zhao and F. Xiao, "Robust Detection Method of Small Targets in Sea-Clutter via Improved Fast Clustering Segmentation," 10.1109/IHMSC.2016.

- 236, pp. 123-126, 2016.
- [2] C. Yang, H. Liu, S. Liao and S. Wang, "Small Target Detection in Infrared Video Sequence using Robust Dictionary Learning," *Infrared Physics & Technology*, Vol. 68, pp. 1-9, 2015
- [3] S. Qi, J. ma, H. Li, S. Zhang and J. Tian, "Infrared Small Target Enhancement via Phase Spectrum of Quaternion Fourier Transform," *Infrared Physics & Technology*, Vol. 62, pp. 50-58, 2014.
- [4] Hiroshi Tasaka, "Everyone has Multiple Personality," Kobunsha Co. Japan, 2015.
- [5] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", arXiv, 2014.
- [6] A. Krizhevsky, I. Sutskever and G. E. Hinton, "ImageNet Classification with Deep Convolution Neural Networks," In Pro. NIPS, 2012.
- [7] S. Bell, P. Upchurch, N. Snavely and K. Bala, "Material Recognition in the Wild with the Materials in Context Database," CoRR, abs/1412.0623, 2014.
- [8] Tao Yang, "Application of Computational Verbs to Feeling Retrieval from Texts," *International Journal of Computational Cognition*, Vol. 4, No. 3, pp. 28-45, 2006.