

형태특징과 지역특징 융합기법을 활용한

열영상 기반의 차량 분류 방법

A Vehicle Classification Method in Thermal Video Sequences using both Shape and Local Features

양 동 원*

Dong Won Yang*

Abstract

A thermal imaging sensor receives the radiating energy from the target and the background, so it has been widely used for detection, tracking, and classification of targets at night for military purpose. In recognizing the target automatically using thermal images, if the correct edges of object are used then it can generate the classification results with high accuracy. However since the thermal images have lower spatial resolution and more blurred edges than color images, the accuracy of the classification using thermal images can be decreased. In this paper, to overcome this problem, a new hierarchical classifier using both shape and local features based on the segmentation reliabilities, and the class/pose updating method for vehicle classification are proposed. The proposed classification method was validated using thermal video sequences of more than 20,000 images which include four types of military vehicles - main battle tank, armored personnel carrier, military truck, and estate car. The experiment results showed that the proposed method outperformed the state-of-the-arts methods in classification accuracy.

요 약

열 영상은 온도에 따라 방출하는 에너지의 차이를 나타낸 영상이다. 주야간 사용이 가능하기 때문에 군사적인 용도로 많이 활용되고 있으나, 열 영상은 물체의 경계가 불명확하고 흐릿하게 표현되는 경우가 많으며 화염 등의 열기로 인해 경계부분이 변질되는 단점이 있다. 따라서, 열 영상을 이용하여 표적의 종류를 분류할 때 정확하게 분할된 경계선을 이용할 경우 효과적으로 분류 할 수 있지만, 물체의 경계가 잘못 추출되는 경우 분류의 정확도가 크게 감소한다. 본 논문에서는 이러한 단점을 극복하기 위해서 표적 영상의 분할 신뢰도에 따라 형태특징과 지역특징의 분류결과를 융합하는 계층적 분류기법을 제안하였으며, 연속 영상 기반으로 분류 결과를 갱신하는 기법을 새롭게 제안하여 차량 표적 분류 정확도를 개선하였다. 제안하는 방법은 실제 군용 표적 4종(전차, 장갑차, 상용차, 군용트럭)이 있는 다양한 자세의 열 영상 20,000장 이상을 이용하여 성능을 검증하였으며, 우수한 성능의 기존 방법 대비 정확도 개선에 효과가 있음을 확인하였다.

Key words : class and pose update, hierarchical classifier, local features, shape features, vehicle classification method

* Ground Technology Research Institute(GTRI), Agency for Defense Development(ADD), Republic of Korea

★ Corresponding author

E-mail : dwyang@add.re.kr, Tel : +82-42-821-3146

Manuscript received Feb. 27, 2020; revised Mar. 21, 2020; accepted Mar. 24, 2020.

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.

I. 서론

컴퓨터 비전분야에서 물체 인식 기법은 영상에서 물체를 자동으로 탐지하고, 분류하고, 물체의 특성을 추출하는 기술을 의미한다. 최근 영상처리 기술 및 컴퓨팅 기술의 혁신적인 발달에 따라 비디오 영상을 기반으로 실시간으로 물체를 탐지하고 자동 분류하는 다양한 기법이 연구되고 있다. 다양한 배경 모션 및 영상 흔들림에 강인하게 이동 물체를 자동으로 탐지하기 위한 다양한 배경 모델링 기법이 제안되었으며[1-5], 탐지된 물체의 자동 분류를 위해서 환경변화에 강인한 지역 특징 추출 기법[6-10]과 형태 특징 추출 기법[11-15]이 제안되었다. 또한, 추출된 특징을 기반으로 기계학습을 수행하기 위한 연구[16-19]가 제시되었다.

군사적인 용도의 물체 인식 기법은 주야간 감시 정찰 목적으로 활용이 가능해야 하기 때문에 일반적으로 열 영상을 사용한다. 열 영상은 배경과 물체의 온도 차이를 밝기 차이로 나타내어서 야간에도 사용할 수 있다는 장점이 있지만, 칼라영상에 비해서 경계가 불분명한 곳과 흐릿하게 나타나는 부분이 많아서 일반적인 칼라 영상 기반의 특징 추출 및 물체 인식 기법을 적용하기 어렵다. 이러한 한계를 극복하기 위해서 열 영상에 적합한 형태 특징 추출 기법이 제안되었으나[15], 이 기법은 형태 특징을 기반으로 하고 있기 때문에 영상 분할 오차가 발생하게 되면 자동 분류 정확도가 크게 감소하게 된다.

본 논문에서는 열 영상을 기반으로 물체 인식하는 기법의 한계점을 극복하고자 다음의 두 가지 새로운 방법을 제안하였다. 첫째, 영상 분할 결과의 신뢰도 추출 결과를 기반으로 형태 특징과 지역 특징의 분류 결과를 융합하여 사용하는 새로운 계층적 분류기법을 제안하였다. 둘째, 비디오 영상의 연속된 분류 결과를 이용하여 차량의 분류 결과와 자세 정보를 갱신하여 분류 정확도를 개선하는 기법을 제안하였다. 두 가지 새로운 방법은 기존 방법과의 비교 실험 결과 차량의 자동 분류 결과를 개선하는데 효과가 있음을 확인하였으며, 열 영상 기반의 차량 분류 기법의 한계를 극복하는데 큰 역할을 했음을 확인하였다. 본 논문의 구성은 다음과 같다. 본론의 1장에서는 제안하는 두 가지 새로운 기법에 대한 상세한 설명과 분석 결과를 나타내었

다. 본론 2장에서는 열 영상 시퀀스를 기반으로 하는 기존 기법과의 비교 실험 결과를 나타내었다. 마지막에는 결론을 나타내었다.

II. 본론

1. 열 영상 기반의 차량 분류 방법

이 장에서는 열 영상 시퀀스를 이용한 제안하는 차량 표적 분류 기법에 대해서 설명한다. 그림 1에 제안하는 차량 표적 분류 기법의 개념도를 나타내었다.




Fig. 1. The overall block diagram of the proposed method.

그림 1. 제안하는 차량 표적 분류 기법 개념도

먼저 입력 영상 시퀀스로부터 표적 후보 영역에 대한 영상 분할을 수행한 뒤, 영상 분할 결과의 신뢰도(R_{seg})를 추출한다[20]. 표적 후보 영역에 대한 열 영상과 분할 영상을 기반으로 형태 특징과 지역 특징을 각각 추출한 뒤 영상 분할 신뢰도를 이용하여 형태 특징을 기반으로 분류한 결과와 지역 특징을 활용한 결과를 계층적 분류기로 융합하여 최종 분류 결과를 나타낸다. 만일 영상 분할 결과의 신뢰도 값이 높을 경우 형태 특징에 의한 분류 결과에 가중치를 두어 분류 결과를 융합하고, 반대로 신뢰도 값이 낮을 경우 영상 분할이 잘못되었을 가능성이 있으므로 지역 특징에 의한 분류 결과에 가중치를 두어 분류 결과를 융합한다. 또한, 분류의 정확도를 높이기 위하여 연속 영상을 기반으로 분류 결과를 갱신하는 기법을 제안하였다. 누적된 분류 결과를 이용하여 발생 가능성이 낮은 표적의 종류와 자세 결과를 배제하고, 변화 가능성이 높은 종류와 자세로 변화할 수 있도록 함으로써 일시적으로 오 분류 되었을 때 보완할 수 있는 방안을 제시하였다. 이와 같이 형태 특징과 지역 특징을 모두 사용할 수 있는 계층적 분류기를 적용하고, 분류 결과를 시간에 따라 누적하여 갱신하는 기법을 적용함으로써, 열 영상 기반의 차량 표적 분류 결과의 정확도를 개선할 수 있었다.

가. Vehicle Classification Method using Both Shape and Local Features

이 절에서는 제안하는 형태 특징과 지역 특징의 분류 결과를 융합하는 계층적 분류기에 대해 설명한다. 먼저, 연속되는 열 영상에서 기존의 배경 모델링 기법[4]을 이용하여 표적의 위치를 자동으로 탐지하고, 표적 영역을 자동으로 분할한다. 자동으로 분할된 표적의 분할 신뢰도($R_{seg}, 0 \leq R_{seg} \leq 1$)는 밝기 분포와 경계 에너지를 분석하는 기법[20]을 활용하여 계산하였다. 형태 특징으로는 형태가 정확하게 나타나는 영상 분할 결과가 있을 때 성능이 매우 우수한 SC(Shape Context)[14]와 TTC(Target Trait Context)[15]를 이용하였으며, 지역 특징으로는 열 영상에서 지역적 특성을 잘 나타내는 HOG(Histograms of Orientation Gradients)[8]와 PHOG(Pyramid HOG)[9]의 기법을 활용하였다. 제안하는 계층적 차량 표적 분류 방법은 다음의 그림 2와 같다.




Fig. 2. The hierachicla classifier for vehicle classification.

그림 2. 차량 표적 분류를 위한 계층적 분류기

먼저 입력 열 영상 및 분할 영상을 이용하여 형태 특징 벡터와 지역 특징 벡터를 추출한다. 이때 형태 특징은 SC와 TTC를 사용할 수 있으며, 지역 특징은 HOG와 PHOG를 추출 할 수 있다. 분류는 그림 3에 나타난 바와 같이 형태 특징과 지역 특징 각각을 이용하여 먼저 분류 확률을 구한 뒤 영상 분할 신뢰도를 기반으로 결과 레벨에서 수식 (1), (2)와 같이 융합을 수행하여 최종 표적 분류 결과를 얻게 된다. 이때, i 는 4종의 표적종류를 나타낸다. ($i=0,1,2,3$) 만일 영상 분할 신뢰도(R_{seg})값이 1에 가까우면 형태특징 분류 결과 확률(P_{shape})이 최종 종류 구분 확률(P_{class})값에 가까워지며, 반대로 신뢰도(R_{seg}) 값이 0에 가까우면 지역 특징 분류 결과 확률(P_{local})이 최종 구분 확률(P_{class})로 쓰이게 된다.

$$P_{class}(i) = R_{seg} \times P_{shape}(i) + (1 - R_{seg}) \times P_{local}(i) \quad (1)$$

$$Class = \underset{i}{\operatorname{argmax}}(P_{class}(i)) \quad (2)$$

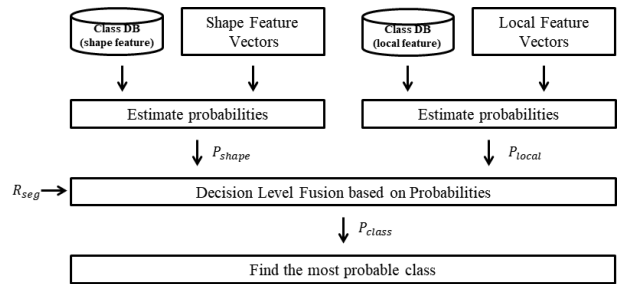


Fig. 3. Decision level fusion method for vehicle class classification.

그림 3. 차량 표적 종류 분류를 위한 결과 융합 방법

위 과정을 통해서 획득한 표적의 종류를 이용하여, 표적 클래스 내의 모델을 선택한다. 각 클래스 내에는 8가지 차량 표적의 자세에 따른 학습 결과를 가지고 있으며, 종류가 결정되면 종류에 맞는 학습 모델을 선택하여 자세 분류를 진행하게 된다. 자세 분류는 표적 종류 분류와 유사한 결과 융합 기법을 적용하였으며(그림 4), 영상 분할 결과를 이용하여 수식 (3), (4)를 기반으로 분류 결과를 최종적으로 결정하였다. 여기서 j 는 8가지 자세의 종류를 나타낸다($j=0,1,2,\dots,7$).

$$P_{pose}(j) = R_{seg} \times P_{shape_{pose}}(j) + (1 - R_{seg}) \times P_{local_{pose}}(j) \quad (3)$$

$$Pose = \underset{j}{\operatorname{argmax}}(P_{pose}(j)) \quad (4)$$

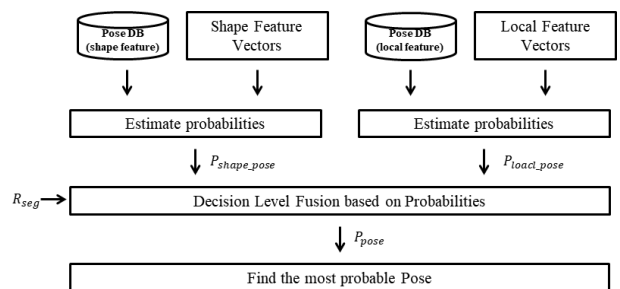


Fig. 4. Decision level fusion for vehicle pose classification.

그림 4. 차량 표적 자세 분류를 위한 결과 융합 방법

만일 형태 특징과 지역 특징 다수를 사용하여 제안하는 방법을 구성 할 때는 각 특징에서 나온 분류 확률을 기반으로 일반화된 결과 융합 방법을 적용할 수 있다. 이때, 결과 융합은 다음의 수식 (5), (6)을 이용할 수 있고, 사용된 symbol은 표 1과 같다.

$$Prob(u_0 = n, \underline{F}) = \frac{1}{N_{F_i=1}} \sum_{i=1}^{N_F} R_{seg}^{s_i} \times (1 - R_{seg}) \times Prob(u_i = n, F_i) \quad (5)$$

$$\hat{k} = \underset{k}{\operatorname{argmax}} Prob(u_0 = k, \underline{F}) \quad (6)$$

Table 1. Symbol definitions.

표 1. Symbol 정의표

Symbol	Definition
u_0	The decision results from decision level fusion
u_i	The decision results from i-th and j-th feature
R_{seg}	Segmentation Reliability ($0 \leq R_{seg} \leq 1$)
F_i	i-th feature set
\underline{F}	All feature set
s_i	Shape feature indicator (for shape feature, for local feature)
N_c	The number of class
N_{FS}	The number of shape feature vectors for decision level fusion
N_{FL}	The number of local feature vectors for decision level fusion
k	The final output class ($1 \leq k \leq N_c$)

나. Class and Pose Update Method

이 절에서는 계층적 분류기의 차량 표적 분류 결과(종류/자세)를 시간에 따라 누적한 뒤 표적의 종류와 자세를 갱신하여 분류 결과의 정확도를 개선하는 방법에 대해 나타내었다. 표적 분류 결과를 갱신하는 기법은 다음의 그림과 같다.




Fig. 5. Class and pose update method using the classification results.

그림 5. 차량 표적 분류 결과 갱신 방법 개념도

계층적 분류기의 결과 값은 종류(Class)값과 자세(Pose)로 받게 되며, 이때 분류 확률 값은 Class Confidence(C)값으로 받는다. 표적의 종류는 한 영상 시퀀스에서 급격하게 변화하지 않을 가능성이 크기 때문에 본 연구에서는 표적의 종류를 markov chain을 기반으로 변동된 값을 반영하도록 제안하

였다. 즉, 표적의 종류는 아래 그림과 같이 총 5회의 연속된 분류 결과 중 4회 이상 같은 종류로 분류하는 경우에만 최종 분류 결과를 출력 가능하도록 제한하였으며, 각 클래스가 바뀌기 위해서는 2회 이상 오분류가 연속으로 나타나는 경우에만 클래스를 변경할 수 있도록 하였다. 또한, 단일 영상의 분류 결과가 임시(Tentative Class), 예약(Reserved Class), 확정(Confirmed Class) 및 기억(Memory Class)의 주기를 거칠 수 있도록 함으로써, 더욱 신뢰성 높은 결과를 제시할 수 있다.

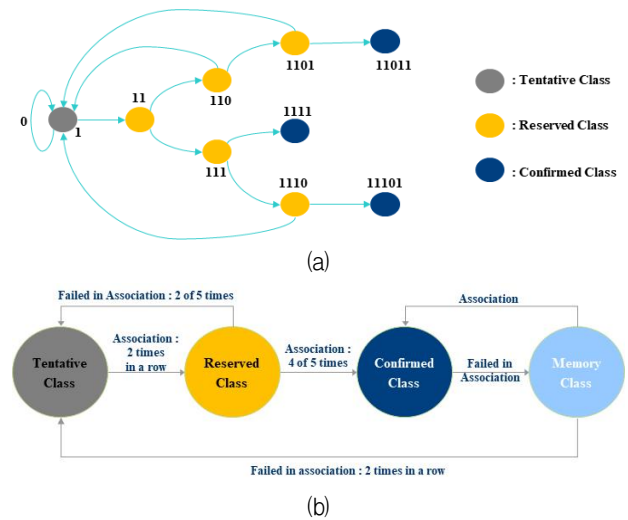


Fig. 6. Markov Chain rules and class cycle for updating method. (a) Markov Chain rules for updating class. (b) Class cycle for update method.

그림 6. 차량 표적 종류 갱신에 적용되는 Markov Chain 규칙 및 순환 주기의 흐름도, (a) 표적 종류 갱신을 위한 Markov Chain Rule, (b) 표적 종류 갱신 순환 주기 흐름도

표적의 종류가 갱신되고 나면, 자세 정보와 분류 신뢰도를 이용하여 자세 결과 갱신을 수행한다. 이때, 영상 시퀀스 내에서 서로 다른 종류로 임의로 변화가 가능한 표적 종류와 달리 동일 클래스 내에서 표적의 자세는 인접 자세로의 변화만 가능함을 알 수 있다. 따라서, 시간에 따라서 변화 가능한 자세의 가능성을 높게 예측하여 연속된 자세 분류 결과 중 오류 가능성이 큰 자세값이 결과로 제시될 경우 갱신 단계에서 배제하는 방법을 적용할 수 있는 MRF(Markov Random Field) [21] 기법을 적용하였다. 표적의 연속되는 sequence를 V 라 하면 V 는 다음의 수식 (7)로 나타낼 수 있다. 또한, 자세 모델을 M_i 이라 하면 이는 수식 (8)로 표현이 가능하다.

$$\text{Vehicle sequence} : V = \{v_1, v_2, \dots, v_t, \dots, v_N\} \quad (7)$$

Model (Pose) sequence :

$$M_t = \{m_{l,1}, m_{l,2}, \dots, m_{l,t}, \dots, m_{l,N}\} \quad (8)$$

이때, 각 자세로 변환 가능성을 확률로 계산하기 위해서, t 시점에서 $m_{l,t}$ 로의 자세 변화 확률을 P 라 하면 다음의 수식(9)-(11)로 계산할 수 있다.

$$\text{Probability} : P(m_{l,t}|V) = \frac{1}{Z(V)} \prod_{t=1}^N F_1(m_{l,t}|V) F_2(m_{l,t}, m_{l,t-1}|V) \quad (9)$$

$$\text{Matching Score} : F_1(m_{l,t}|V) = \text{Prob}(m_{l,t}) \quad (10)$$

Model Transition Factor :

$$F_2(m_{l,t}, m_{l,t-1}|V) = \exp(-\lambda \|\theta_{l,t} - \theta_{l,t-1}\|^2) \quad (11)$$

여기서 $Z(V)$ 는 $P(m_{l,t}|V)$ 를 확률분포 값으로 만드는 계수이며, λ 는 자세변화 가능성을 조절 하는 상수이고, θ 는 자세의 각도 값을 나타낸다. 이때, 확률(Prob) 값은 입력받은 분류 신뢰도(C) 값을 사용할 수 있다. 수식 (9)로부터 계산된 확률을 이용하여 현재 시점에서 선택 가능한 가장 확률 높은 model 을 수식 (12)를 통해서 계산할 수 있다.

$$\text{Pose update} : \hat{M}_t = \underset{M_t}{\text{argmax}} P(m_t|V) \quad (12)$$

위의 계산을 통해서 각 차량은 변화 가능성이 가장 큰 자세를 연속적으로 계산 할 수 있으며, 최적의 자세 모델을 선택 할 수 있게 된다. 그림 7에 자세 분류가 적용된 추론 과정을 그림으로 나타내었다. 갱신 된 표적의 종류와 자세는 최종적으로 이전 결과에서 크게 벗어나는 결과가 나타나는지 한번 더 검증 과정(Class and Pose Refinement)을 거친 뒤 최종 결과로 출력된다. 이때, 종류는 확정 클래스와 기억 클래스가 아닌 결과가 나오게 되면 미확인으로 표현하게 되고, 종류가 미확인인 경우 자세도 미확인으로 변경하여 출력한다. 만일 표적이 확정 혹은 기억 클래스인 경우 표적의 종류가 최종 결과로 출력되며, 자세는 갱신된 자세를 출력하게 된다. 제안 방법은 위에서 논의된 바와 같이 표적의 종류와 자세를 단일 영상에서 그 결과를 나타내지 않고, 연속 영상 기반으로 결과값을 갱신 처리함으로써, 일시적인 표적 종류의 오분류 및 자세 추정 오차를 최소화 할 수 있었으며, 다음 장에서 실제 영상 기반의 실험 결과를 통해서 개선 효과를 확인 할 수 있었다.

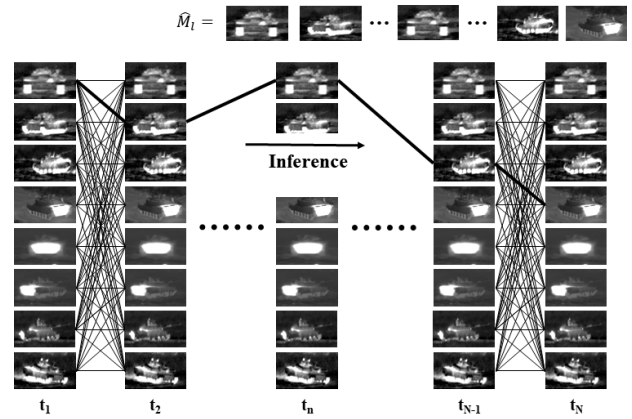


Fig. 7. Pose inference example using MRF (Markov Random Field).

그림 7. 표적 자세 갱신을 위한 추론 과정의 예

2. 실험 결과

본 논문에서 제안하는 차량표적 분류 기법의 분류 정확도 개선 효과를 검증하기 위해서 다양한 자세의 실 표적이 존재하는 열 영상 시퀀스를 이용하여 분류 정확도 실험을 수행하였다. 실험에 사용한 표적은 총 4종(전차, 장갑차, 군용트럭, 상용차)이며 각각 8방향(0°, 45°, 90°, 135°, 180°, 225°, 270°, 315°)의 자세 영상을 활용하였다. 시계방향 및 반시계방향으로 회전하는 영상 시퀀스 8종을 이용하여 총 20,000 frames 이상의 영상을 활용하여 성능을 분석하였다.

가. Experiment Environment

성능 분석을 하기 위해서 기계학습에 사용된 영상의 조건은 다음의 표와 같다. 입력 영상은 4종의 차량 표적이며, 모든 영상은 중적외선 영상이다. 학습을 위한 데이터는 표적 인근 200×100 pixel을 사용하였다. 학습에는 표적 종류 4종에 8자세를 고려하여 각 자세별 100장씩을 사용하였다. 학습 방법은 다양한 결과 비교를 위해서 학습 데이터를 4종류로 나누어 분류하는 방법과 각 자세도 하나의 클래스로 구별하는 32종류로 구별하는 두 가지 방법을 학습에 적용하였으며, 기계학습 방법은 SVM (Support Vector Machine) [16-17] 방법과 RF (Random Forest) [18-19] 방법 두 가지를 적용하였다. 또한, 공정한 성능 비교를 위해서 지역 특징 중 열 영상에서 성능이 우수한 HOG[8]와 PHOG[9]를 사용한 결과와 형태 특징 중 성능이 우수한 SC [14]와 TTC[15]를 적용한 방법의 결과를 비교하였

다. 따라서, 각 방법은 사용한 특징과 학습에 사용한 종류의 수 및 분류기에 따라 그 성능을 비교 분석하였으며 이를 구별하기 위해서 HOG-4-SVM(HOG 특징 사용, 4종으로 학습, SVM 이용), PHOG-32-RF(PHOG 특징 사용, 32종으로 학습, RF 이용) 등으로 구별하여 표기하였다.

Table 2. Specification of the thermal images used in the experiments.

표 2 실험에 사용한 표적 및 영상 시퀀스 사양

Classes	MBT(Main Battle Tank), APC(Armored Personnel Carrier), EC(Estate Car), MT(Military Truck)
IR Band	Middle Wave IR (3~5μm)
Image Size	200×100 pixel
Number of Training Images	100×4×8=3200 images
Number of Test Sequences	2×4=8 sequences
Average # of frames/sequence	About 2500 frames
Number of Test Images	Over 20,000 frames

표적 분류 정확도 실험에 test sequences로 사용된 영상 시퀀스는 모두 8종류이며, 각 종류별로 2

종류의 영상(시계방향 회전(CW: Clockwise), 반시계방향 회전(CCW: Counter Clockwise))이 사용되었다. 각 영상 시퀀스의 예를 그림 9, 10에 나타내었다.

나. Class and Pose Recognition Test

제안하는 방법과 비교 대상 방법은 모두 동일한 학습 데이터와 테스트 영상을 활용하여 표적 분류 정확도 시험을 수행하였다. 먼저, 표적의 종류를 정확하게 분류하는 가를 분석하였으며, 분석 결과는 다음의 표 3과 같다. 표적 종류 분류 실험 결과 제안하는 방법(Proposed-4-SVM, Proposed-32-RF)이 기존의 방법들 대비 성능이 확연히 개선되었음을 확인하였다. 실제 표적에 대한 영상 분할 결과에 따라 특정 시퀀스는 지역특징이 다른 영상시퀀스는 형태 특징의 결과가 우수한 것을 확인 할 수 있으나, 제안하는 방법은 두 가지 방법의 장점을 계층적 분류기와 결과 갱신 방법을 통해서 융합하고 있음을 확인 할 수 있었다.

다음으로 표적의 종류 및 자세를 정확하게 분류하는 가를 분석하였으며, 분석 결과는 다음의 표 4와 같다. 표적 종류 및 자세 분류 실험 결과는 종류만 구별하는 경우보다 제안하는 방법의 장점이 더 많이 나타났음을 알 수 있다. 제안하는 방법(Proposed-




Fig. 8. Example images of the test sequences #1 (Main Battle Tank and Armored Personnel Carrier).

그림 8. 테스트에 사용된 열 영상 시퀀스 예 #1 (전차, 장갑차 영상)

No.	IR Images							
#5 EC Day (CW)								
Frame	25 (0°)	79 (45°)	313 (90°)	685 (135°)	781 (180°)	871 (225°)	1201 (270°)	1507 (315°)
#6 EC Night (CCW)								
Frame	253 (45°)	607 (0°)	739 (315°)	907 (270°)	1105 (225°)	1267 (180°)	1375 (135°)	1525 (90°)
#7 MT Day (CW)								
Frame	572 (180°)	782 (225°)	1364 (270°)	1856 (315°)	2102 (0°)	2390 (45°)	3020 (90°)	3368 (135°)
#8 MT Night (CCW)								
Frame	145 (90°)	625 (45°)	775 (0°)	955 (315°)	1267 (270°)	1561 (225°)	1909 (180°)	2341 (135°)

Fig. 9. Example images of the test sequences #2 (Estate Car and Military Truck).

그림 9. 테스트에 사용된 열 영상 시퀀스 예 #2 (상용차, 군용트럭 영상)

32-RF)의 경우 65% 이상의 정확도를 기록함을 확인할 수 있었으며, 이는 지역 특징과 형태 특징을 이용하는 기법의 단점이 보완 되었으며, 제안하는 결과 갱신 기법으로 자세를 추정할 때 더 정확도 높은 결과를 추정 할 수 있음을 확인할 수 있었다.

즉, 비교적 분명한 4종류의 표적을 분류하는 경우 보다 훨씬 유사성이 높은 종류 및 자세를 분류하는 경우 제안하는 방법으로 최적의 성능을 이끌어냄으로써 분류 결과를 65% 이상으로 개선해 낼 수 있었음을 확인할 수 있다.

Table 3. Vehicle Class Classification Results.

표 3. 표적 종류 분류 실험 결과 표

Feature-Class-Classifier	Class Average rate	Main Battle Tank		Armored Personnel Carrier		Estate Car		Military Truck		
		Sequence #1	Sequence #2	Sequence #3	Sequence #4	Sequence #5	Sequence #6	Sequence #7	Sequence #8	
HOG	HOG-4-SVM	90.29	86.38	95.07	100.00	74.32	99.65	82.18	98.95	85.75
	HOG-32-SVM	87.28	79.36	93.90	98.55	75.68	100.00	83.69	85.75	81.31
	HOG-4-RF	91.41	93.83	97.18	96.82	72.16	98.27	96.37	99.57	77.10
	HOG-32-RF	91.83	94.26	97.42	97.11	74.86	97.23	94.86	97.62	81.31
PHOG	PHOG-4-SVM	89.87	97.66	96.48	99.13	75.68	97.23	75.53	99.47	77.80
	PHOG-32-SVM	87.09	91.06	89.67	96.82	76.49	96.19	74.92	96.54	75.00
	PHOG-4-RF	90.63	98.51	97.89	96.82	69.73	96.54	83.08	97.62	84.81
	PHOG-32-RF	89.96	96.81	96.95	98.84	75.41	96.19	76.13	98.27	81.07
SC	SC-4-SVM	75.86	76.60	82.39	73.99	67.57	97.92	80.97	67.89	59.58
	SC-32-SVM	79.43	83.40	88.26	76.01	65.41	99.31	81.87	73.65	67.52
	SC-4-RF	69.63	76.60	84.98	55.49	58.65	99.31	75.83	53.13	53.04
	SC-32-RF	76.98	88.51	91.55	70.52	60.54	100.00	77.64	65.87	61.21
TTC	TTC-4-SVM	84.95	85.53	95.07	95.38	66.22	99.65	83.38	86.58	67.76
	TTC-32-SVM	84.62	85.53	92.72	93.93	68.38	98.96	83.69	79.48	74.30
	TTC-4-RF	83.92	94.26	98.83	89.88	66.22	97.92	80.06	76.67	67.52
	TTC-32-RF	86.70	98.30	99.06	93.93	69.46	95.16	79.76	82.72	75.23
Proposed	Proposed-4-SVM	93.28	100.00	100.00	100.00	79.10	100.00	82.12	97.18	87.80
	Proposed-32-SVM	92.31	97.70	98.43	99.39	80.36	100.00	81.76	97.32	83.53
	Proposed-4-RF	91.39	100.00	100.00	97.49	71.92	100.00	82.80	91.42	87.50
	Proposed-32-RF	93.34	100.00	100.00	100.00	79.65	98.51	82.14	98.53	87.87

Table 4. Vehicle Class and Pose Classification Results.

표 4. 표적 종류 및 자세 분류 실험 결과 표

Feature-Class-Classifier	Class and Pose	Main Battle Tank		Armored Personnel Carrier		Estate Car		Military Truck		
	Average rate	Sequence #1	Sequence #2	Sequence #3	Sequence #4	Sequence #5	Sequence #6	Sequence #7	Sequence #8	
HOG	HOG-4-SVM	54.50	59.36	61.97	79.48	53.78	55.02	58.91	26.84	40.65
	HOG-32-SVM	58.75	64.26	66.43	81.50	56.22	62.28	60.73	30.45	48.13
	HOG-4-RF	58.33	72.34	66.43	73.70	51.62	60.90	59.52	32.83	49.30
	HOG-32-RF	59.86	71.91	70.19	75.43	55.68	64.01	60.12	31.32	50.23
PHOG	PHOG-4-SVM	57.22	67.02	60.33	72.83	48.38	64.71	58.31	50.00	36.21
	PHOG-32-SVM	57.16	65.74	62.68	71.68	48.38	67.13	57.10	42.76	41.82
	PHOG-4-RF	58.40	70.85	54.93	72.83	49.46	64.71	59.82	43.20	51.40
	PHOG-32-RF	59.92	71.70	61.74	77.46	51.08	68.17	58.91	41.68	48.60
SC	SC-4-SVM	47.65	49.15	51.88	41.62	47.57	63.67	61.03	26.84	39.49
	SC-32-SVM	51.48	54.68	57.75	49.13	47.30	64.01	61.63	34.56	42.76
	SC-4-RF	42.74	44.89	56.81	35.55	38.92	60.21	57.40	20.30	27.80
	SC-32-RF	48.50	53.19	61.74	45.09	41.35	63.67	59.21	28.73	35.05
TTC	TTC-4-SVM	55.11	58.30	65.26	70.81	46.22	55.36	58.01	45.79	41.12
	TTC-32-SVM	56.22	53.19	62.68	70.52	44.32	67.47	61.63	43.20	46.73
	TTC-4-RF	56.89	60.21	65.96	68.21	46.49	68.51	63.14	38.23	44.39
	TTC-32-RF	60.25	61.28	66.90	70.23	49.19	69.20	63.44	50.11	51.64
Proposed	Proposed-4-SVM	63.67	72.14	71.95	75.15	51.94	61.89	64.57	55.77	55.95
	Proposed-32-SVM	61.22	65.90	68.50	76.06	52.08	64.89	64.82	51.58	45.95
	Proposed-4-RF	62.99	67.41	68.36	75.86	51.10	69.23	66.24	46.32	59.38
	Proposed-32-RF	65.90	63.60	68.45	78.03	54.28	75.00	67.21	55.99	64.69

III. 결론

본 논문에서는 열 영상 시퀀스를 이용하여 표적 차량의 종류와 자세를 자동으로 분류하는 새로운 기법을 제안하였다. 제안하는 기법은 형태 특징과 지역 특징의 장점을 결합하기 위한 영상 분할 신뢰도 기반의 계층적 분류기법을 사용하였으며, 연속 영상의 특징에 적합한 결과 갱신 기법을 적용하여 정확도를 개선하고자 하였다. 본 논문의 제안 방법은 군용 표적이 있는 실 영상 20,000장 이상의 영상을 이용하여 그 성능을 확인하였으며, 성능이 우수한 지역특징과 형태특징을 사용하는 방법 대비 종류 및 자세 방법에서 정확도를 크게 개선 할 수 있음을 확인하였다. 본 논문의 제안 방법은 추후 다양한 종류의 열 영상을 추가 확보하여 그 분류 성능을 지속적으로 검증하고 보완해 나갈 예정이다.

References

[1] N. Goyette, P.-M. Jodoin, F. Porikli, J. Konrad, and P. Ishwar, "A Novel Video Dataset for Change Detection Benchmarking," *IEEE Trans. on Image*

Process., No.23, No.11, pp.4663-4679, 2014.

DOI: 10.1109/TIP.2014.2346013

[2] Y. Benezeth, P.-M. Jodoin, B. Emile, H. Laurent, and C. Rosenberger, "Comparative study of background subtraction algorithms," *J. Electron. Imag.*, Vol.19, No.3. 2010. DOI: 10.1117/1.3456695

[3] M. S. Allili, N. Bouguila, and D. Ziou, "Finite general Gaussian mixture modeling and application to image and video foreground segmentation," *J. Electron. Imag.*, Vol.17, No.1, 2008.

DOI: 10.1109/CRV.2007.33

[4] O. Barnich, and M. V. Droogenbroeck, "ViBe: A Universal Background Subtraction Algorithm for Video Sequences," *IEEE Trans. Image Process.*, Vol.20, No.6, pp.1709-1724, 2011.

DOI: 10.1109/TIP.2010.2101613

[5] M. V. Droogenbroeck and O. Paquot, "Background Subtraction: Experiments and Improvements for ViBe," in *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, pp.32-37, 2012. DOI: 10.1109/CVPRW.2012.6238924

[6] D. G. Lowe, "Distinctive image features from

scale-invariant keypoints,” *Int. J. Comput. Vis.*, Vol.60, pp.91–110, 2004.
DOI: 10.1023/B:VISI.0000029664.99615.94

[7] H. Bay, T. Tuytelaars, and L. V. Gool, “SURF: Speeded Up Robust Features,” in *Proc. Eur. Conf. Comput. Vis.*, pp.404–417, 2006.
DOI: 10.1007/11744023_32

[8] N. Dalal, and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” in *Proc. IEEE Int. Conf. Comput. Vis. Pattern Recognit.*, vol.1, pp.886–893, 2005. DOI: 10.1109/CVPR.2005.177

[9] A. Bosch, A. Zisserman, and X. Munoz, “Representing shape with a spatial pyramid kernel,” in *Proc. of the 6th ACM Int. Conf. on Image and Video Retrieval*, pp.401–408, 2007.
DOI: 10.1145/1282280.1282340

[10] P. F. Felzenszwalb, R. B. Girshick, D. McAllester, and D. Ramanan, “Object Detection with Discriminatively Trained Part-Based Models,” *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.32, No.9, pp.1627–1645, 2010.
DOI: 10.1109/TPAMI.2009.167

[11] A. Oliva, and A. Torralba, “Building the gist of a scene: the role of global image features in recognition,” *Progress in Brain Research*, vol.155, pp.23–36, 2006. DOI: 10.1.1.304.2750

[12] H. Riemenschneider, M. Donoser, and H. Bischof, “Using Partial Edge Contour Matches for Efficient Object Category Localization,” in *Proc. Eur. Conf. Comput. Vis.*, pp.29–42, 2010.
DOI: 10.1007/978-3-642-15555-0_3

[13] Y. Mingqiang, K. Kidiyo, and R. Joseph, “A survey of shape feature extraction techniques,” *Pattern Recognit.*, pp.43–90, 2008. DOI: 10.5772/6237

[14] S. Belongie, J. Malik, and J. Puzicha, “Shape Matching and Object Recognition Using Shape Contexts,” *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.24, No.24, pp.509–522, 2002.
DOI: 10.1109/34.993558

[15] D. W. Yang, H. W. Park, “A New Shape Feature for Vehicle Classification in Thermal Video Sequences,” *IEEE Trans. Circuits Syst. Video Technol.*, Vol.26, No.7, pp.1363–1375, 2016.

DOI: 10.1109/TCSVT.2015.2452780

[16] C. C. Chang, and C. J. Lin, “LIBSVM: A Library for Support Vector Machines,” <http://www.csie.ntu.edu.tw/~cjlin/papers/libsvm.pdf>, 2012.

[17] B. Waske, and J. A. Benediktsson, “Fusion of Support Vector Machines for Classification of Multisensor Data,” *IEEE Trans. Geosci. Remote Sens.*, Vol.45, No.12, pp.3858–3866, 2007.
DOI: 10.1109/TGRS.2007.898446

[18] L. Breiman, “Random Forests,” *Machine Learning*, Vol.45, pp.5–32, 2001.
DOI: 10.1023/A:1010933404324

DOI: 10.1023/A:1010933404324

[19] B. C. Ko, D-Y. Kim, J-H. Jung, and J-Y. Nam, “Three-level cascade of random forests for rapid human detection,” *Optical Engineering*, Vol.52, No.2, pp.027204(1–9), 2013.
DOI: 10.1117/1.OE.52.2.027204

DOI: 10.1117/1.OE.52.2.027204

[20] D. W. Yang, Y. Lee, D. Kwak, “A Study on Vehicle Target Classification Method Using Both Shape and Local Features with Segmentation Reliability,” *Journal of KIMST (Korea Institute of Military Science and Technology)*, Vol.20, No.1, pp.40–47, 2017.
DOI: 10.9766/KIMST.2017.20.1.040

DOI: 10.9766/KIMST.2017.20.1.040

[21] M. Hodlmoser, B. Micusik, M.-Y. Liu, M. Pollefeys, M. Kampel, “Classification and Pose Estimation of Vehicles in Videos by 3D Modeling within Discrete-Continuous Optimization,” *3DIMPVT (3D Imaging, Modeling, Processing, Visualization and Transmission)*, 2012.
DOI: 10.1109/3DIMPVT.2012.23

DOI: 10.1109/3DIMPVT.2012.23

BIOGRAPHY

DongWon Yang (Member)



2001: B.S. degree in Electrical Engineering, Seoul National University.
2003: M.S. degree in Electrical Engineering, Seoul National University.
2016: Ph.D. degree in Electrical Engineering, KAIST.

2003~Present : Senior Research Engineer, Agency for Defense Development(ADD).