

표적의 기하학적 변환에 강인한 SIFT 기반의 표적 분류 알고리즘 설계

Design of a SIFT based Target Classification Algorithm robust to Geometric Transformation of Target

이희열* · 김종환* · 김세윤* · 최병재** · 문상호*** · 박길흠*

Hee-Yul Lee*, Jong-Hwan Kim*, Se-Yun Kim*, Byung-Jae Choi**, Sang-Ho Moon*** and Kil-Houm Park*

* 경북대학교 전자공학과

** 대구대학교 전자공학부

*** 영남이공대학교 모바일과

요 약

본 논문은 표적의 회전, 크기 변화, 이동 변화, 자세변화 등의 기하학적 변환에 강인한 표적 분류 방법을 제안한다. 우선 표적의 회전, 크기변화, 이동 변화에 대해서는 SIFT(Scale-Invariant Feature Transform) 특징 벡터들의 유사도, 스케일 비, 오리엔테이션의 범위들을 이용한 CM(Confidence Map)에 기반하여 표적을 분류한다. 한편 표적의 자세 변화에 대응하기 위해 다양한 각도에서 획득한 표적 영상의 DB(database)를 이용한다. 각도의 범위는 실행 시간과 샘플링 간격에 따른 성능을 비교, 분석하여 결정한다. 제안한 표적 분류 방법의 성능을 평가하기 위해 기하학적 변화가 있는 여러 가지 영상에 대해 실험한다. 실험을 통해 제안 알고리즘이 우수한 분류 성능을 보임을 증명한다.

키워드 : SIFT, 특징 선택, confidence map, 표적 분류

Abstract

This paper proposes a method for classifying targets robust to geometric transformations of targets such as rotation, scale change, translation, and pose change. Targets which have rotation, scale change, and shift is firstly classified based on CM(Confidence Map) which is generated by similarity, scale ratio, and range of orientation for SIFT(Scale-Invariant Feature Transform) feature vectors. On the other hand, DB(DataBase) which is acquired in various angles is used to deal with pose variation of targets. Range of the angle is determined by comparing and analyzing the execution time and performance for sampling intervals. We experiment on various images which is geometrically changed to evaluate performance of proposed target classification method. Experimental results show that the proposed algorithm has a good classification performance.

Key Words : SIFT, feature selection, confidence map, target classification

1. 서 론

자동표적인식(Automatic Target Recognition) 시스템은 사람의 시각적 판단을 대신해서 표적의 정보를 획득하고 이를 자동으로 인식하는 시스템이다. 기본적인 ATR 시스템의 구조는 영상 내 잠재적 표적을 찾아내는 표적 탐지

(target detection), 탐지된 표적에서 정확히 배경과 표적을 분리하는 분할(segmentation), 특징 추출(feature extraction) 및 선택(selection), 인식(recognition) 및 분류(classification), 추적(tracking) 등의 단계로 이루어져 있다 [1].

ATR 시스템에서 널리 사용되는 IR(infrared) 센서는 야간 시야 확보 및 감시가 가능하다는 장점이 있지만 온도 변화에 따른 영상의 가변성 때문에 표적을 인식하기에 많은 어려움이 따른다. CCD 센서에 의해 획득된 영상은 적외선 영상보다 고해상도의 영상을 얻을 수 있으며, 계절 및 온도에 의한 제약이 크지 않다. 따라서 적외선 영상만으로 인식이 불가능한 환경일 경우, CCD 영상 기반의 인식 기법을 적용함으로써 시스템 성능의 극대화를 모색할 수 있다.

기존의 특징 추출 방법 중 표적의 윤곽선에 기반한 방법

접수일자 : 2009년 6월 6일

완료일자 : 2009년 12월 13일

* 본 연구는 국방과학연구소 “표적획득지능화 연구” 과제의 지원(계약번호:UD080034ID)을 통해 수행되었음.

* 본 연구는 지식경제부 및 정보통신연구진흥원의 대학 IT연구센터 지원사업의 연구결과로 수행되었음 (IITA-2008-(109008040002-0001000100100))

[2-4]은 배경과 표적을 정확히 분리하는 분할 단계에 크게 영향을 받는다. 하지만 실제 전장에서 CCD 영상 내 표적은 복잡한 배경을 가지고 다양한 장소에서의 배경 변화를 예측하기 어렵기 때문에 표적을 배경으로 부터 정확히 분할하기가 어렵다.

최근에 국부적 불변 특징(local invariant features)에 기반한 물체 인식 방법이 많은 연구에서 뛰어난 성능을 보이고 있다 [5]. Lowe [6]는 크기, 회전, 이동에 불변인 DoG(Difference of Gaussian)의 극점을 특징점으로 제시하였다. Mikolajczyk와 Schmid [7]는 아핀변환(affine transformation)에 불변인 특징점을 제시 하였고, 후에 크기와 아핀변환에 불변인 특징점 [8]으로 발전 시켰다. Ke와 Sukthar [9]는 SIFT [10]에 PCA를 접목시킨 새로운 서술자(descriptor)를 제안 하여 성능을 향상시켰다. 특히, Mikolajczyk와 Schmid [5]는 다양한 지역 서술자의 성능을 비교, 분석하여 크기 및 회전 변화에 SIFT가 뛰어난 성능을 보임을 입증하였다.

군사적 목적의 표적은 다양한 거리에서 측정될 수 있고, 굴곡이 있는 지형 또는 장애물 때문에 차체가 기울어질 수 있기 때문에, 크기 및 회전 변화에도 재현성 있게 지역적 특징을 표현할 수 있는 서술기법이 필요하다. 따라서 본 논문에서는 SIFT 특징점과 표적 중심의 상대적 위치정보를 이용하여 신뢰성 있는 특징 벡터를 선별하고, CM(confidence map)을 이용한 분류 방법을 제안한다. 각 클래스의 CM은 입력 영상의 각 화소가 표적의 중심으로 추정되는 정도를 수치화한 영상이다. 2장에서는 표적의 자세 변화를 고려한 DB(database) 영상과 특징 벡터의 구성 방법을 설명하고, 3장에서는 DB 영상과 입력 영상에서 추출된 특징 벡터 사이의 비교를 통해 표적의 특징만을 선택하고, CM을 이용한 분류 방법을 제안한다. 4장에서는 다양한 실험을 통해 제안한 표적 분류 알고리즘을 분석하고 SIFT 특징벡터 사이의 유클리디안 거리를 이용한 방법과 제안한 방법의 인식률을 비교함으로써 제안 방법의 우수한 성능을 증명하고, 5장에서 결론을 맺는다.

2. DB 영상과 특징 벡터의 구성 방법

DB는 그림 1과 같이 다양한 시점에서 바라본 표적영상으로 구성하였다. 이는 다양한 자세에서 표적의 특징 정보를 확보할 수 있도록 해준다. 이렇게 얻어진 DB 영상에 SIFT를 이용한 특징 벡터를 추출한다. 여기에 표적 중심을 추정하기 위한 특징 벡터와 표적 중심사이의 상대적 위치 정보를 추가한다. 이 정보는 입력영상에서 신뢰성 있는 표적 중심을 추정하기 위하여 사용된다.

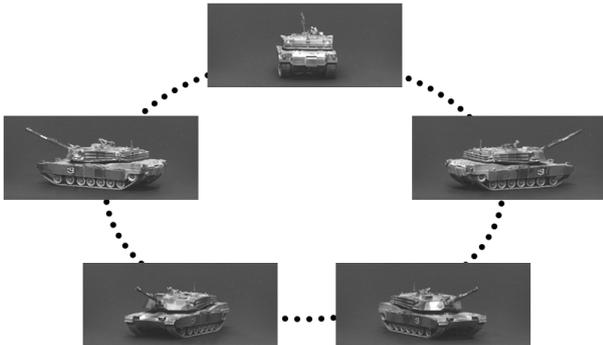


그림 1. DB의 구성에 사용된 영상.

Fig. 1. The images in database.

그림 2에 나타난 점 P는 SIFT 특징점(keypoint) 중 하나를 나타내고 점 Q는 표적의 중심에 해당하는 영상의 가로, 세로 중심점을 나타낸다. d 는 두 점 사이의 거리를 나타내고 θ 는 벡터 \vec{PQ} 가 지면과 이루는 각을 나타낸다. 두 점 사이의 상대적 위치를 나타내는 순서쌍 (d, θ) 을 점 P의 SIFT 특징 벡터에 추가한다.

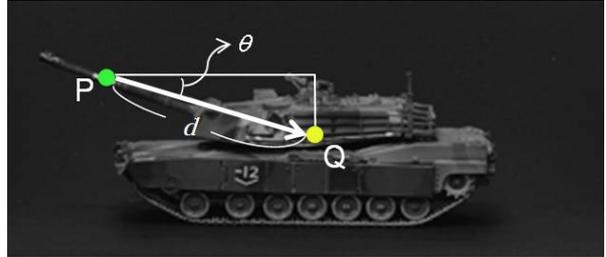


그림 2. 특징점과 표적 중심의 상대적 위치.

Fig. 2. Relative location between feature point and center of target.

분류하고자 하는 표적이 N개라 하면, 위와 같은 과정을 각 클래스에 수행하여 식 (1)과 같이 N개의 특징 벡터 집합을 얻는다.

$$\begin{aligned} \text{Class1} &= \{(f_{1,1}, c_{1,1}), (f_{1,2}, c_{1,2}), \dots, (f_{1,m_1}, c_{1,m_1})\} \\ \text{Class2} &= \{(f_{2,1}, c_{2,1}), (f_{2,2}, c_{2,2}), \dots, (f_{2,m_2}, c_{2,m_2})\} \\ &\dots \\ \text{ClassN} &= \{(f_{N,1}, c_{N,1}), (f_{N,2}, c_{N,2}), \dots, (f_{N,m_N}, c_{N,m_N})\} \end{aligned} \quad (1)$$

여기서 m_i 는 i -th 클래스의 DB영상에서 찾은 특징벡터의 개수이다($1 \leq i \leq N$). $f_{i,j}$ 는 i -th 클래스의 DB영상에서 얻은 j -th SIFT 특징 벡터를 나타내고($1 \leq j \leq m_i$), $c_{i,j}$ 는 $f_{i,j}$ 의 위치와 표적중심의 위치사이의 상대적 위치를 나타내는 순서쌍이다.

입력 영상에도 식 (2)과 같은 특징벡터 집합을 얻는다. 입력영상은 DB영상과 달리 표적중심이 영상의 중심에 있지 않기 때문에 표적의 중심위치는 집합에 포함되지 않는다.

$$\text{Input} = \{f_{in,1}, f_{in,2}, \dots, f_{in,m_{in}}\} \quad (2)$$

3. 새로운 표적 분류 알고리즘의 설계

앞으로 논의의 편의를 위해서 SIFT 특징 벡터 f 와 관련한 몇 가지 정의를 다음과 같이 내린다.

1. $ScI(f)$: f 의 스케일
2. $Ori(f)$: f 의 오리엔테이션
3. $X_{pos}(f)$ 와 $Y_{pos}(f)$: f 의 가로, 세로 위치

3.1. 특징 벡터의 선택

Input 집합에 있는 특징 벡터들은 배경과 표적내부에서 모두 추출된다. 이 중에서 DB와 입력영상특징벡터 사이의 유사도, 스케일 비, 오리엔테이션의 범위 등을 고려해서 표

적의 정보를 가진 특징 벡터를 선별한다.

먼저 유사도가 높은 특징 벡터를 선택하기 위해서 유클리디안 거리를 사용한다. 유사도에 의해서 선택되어진 입력 특징 벡터 집합($D_i(Input)$)은 식 (3)과 같이 가장 유사한 DB의 특징 벡터와의 쌍으로 표현된다.

$$D_i(Input) = \{(f_{in,j}, f_{i,k}) \mid \|f_{in,j} - f_{i,k}\| < T_d \text{ and } k = \arg \min_c \|f_{in,j} - f_{ic}\|\} \quad (3)$$

여기서 i, j, c 의 범위는 $1 \leq i \leq N, 1 \leq j \leq m_{in}, 1 \leq c \leq m_i$ 이다. 또한 임계값 T_d 을 두어 거리가 큰 특징 벡터를 제거하였다. 실험에서 T_d 는 160000을 사용하였다. 이 값은 잘 매칭된 화소끼리의 거리 분포를 이용하여 미리 정해놓은 값이다.

다음은 특징 벡터의 스케일 비를 선택기준으로 사용한다. $D_i(Input)$ 집합은 입력 영상의 특징 벡터와 DB 영상의 특징 벡터로 구성된 순서쌍을 원소로 가지기 때문에 각 원소마다 DB 영상의 특징벡터의 스케일에 대한 입력 영상의 특징 벡터의 스케일 비($Scl(f_{in,j})/Scl(f_{i,k})$)를 계산할 수 있다. 배경이 아닌 표적으로부터 추출된 특징 벡터의 스케일 비는 모두 유사하게 나타나기 때문에, 스케일 비는 선택기준으로 적합하다. 스케일 비에 의해서 선택되어진 입력 특징 벡터 집합($DS_i(Input)$)은 다음 식 (4)와 같이 표현된다.

$$DS_i(Input) = \{(f_{in,j}, f_{i,k}) \mid (f_{in,j}, f_{i,k}) \in D_i(Input) \text{ and } avr_s - 0.1 < Scl(f_{in,j})/Scl(f_{i,k}) < avr_s + 0.1\} \quad (4)$$

여기서 avr_s 는 스케일 비의 평균이다. 표적의 거리를 사전정보로 알고 있다면, avr_s 을 구할 때 $D_i(Input)$ 집합 내의 모든 데이터를 사용하지 않고, 스케일 비의 범위를 제한하여 avr_s 을 구하여 좀 더 정확한 결과를 얻을 수 있다.

지상표적은 항공표적과는 달리 그 기울어짐이 지형의 변화에 따라 한정된다. 따라서 오리엔테이션의 변화가 크지 않은 특징 벡터를 선택한다. 오리엔테이션의 변화에 의해서 선택되어진 입력 벡터 집합($DSO_i(Input)$)은 다음 식 (5)와 같이 나타낸다.

$$DSO_i(Input) = \{(f_{in,j}, f_{i,k}) \mid (f_{in,j}, f_{i,k}) \in DS_i(Input) \text{ and } |Ori(f_{in,j}) - Ori(f_{i,k})| < T_o\} \quad (5)$$

실험에서 T_o 는 15° 를 사용하였다.

이와 같은 과정을 N개의 모든 Class에 적용하여 각 클래스마다 특징 벡터 집합 $DSO_i(Input)$ 을 얻는다.

3.2. Confidence Map의 생성과 분류

선별된 특징 집합 $DSO_i(Input)$ 을 이용하여 입력 영상의 각 화소가 표적의 중심일 가능성을 수치화한 각 클래스의 CM(confidence map)을 생성한다. i 클래스의 CM(CM_i)을 생성하는 방법은 다음과 같다.

$(f_{in,j}, f_{i,k})$ 가 $DSO_i(Input)$ 집합의 한 원소라고 하면, $f_{i,k}$ 와 중심의 상대적 위치를 나타내는 $c_{i,k} = (d_{i,k}, \theta_{i,k})$ 을 보정하여 $f_{in,j}$ 에 대응되는 표적의 상대적 중심 위치 ${}^i c_{in,j} = ({}^i d_{in,j}, {}^i \theta_{in,j})$ 을 다음 식 (6) 및 (7)과 같이 추정한다.

$${}^i d_{in,j} = d_{i,k} \times \frac{Scl(f_{in,j})}{Scl(f_{i,k})} \quad (6)$$

$${}^i \theta_{in,j} = \theta_{i,k} - (Ori(f_{in,j}) - Ori(f_{i,k})) \quad (7)$$

입력 영상의 특징점 $f_{in,j}$ 의 위치와 추정된 상대적 중심 위치 ${}^i c_{in,j}$ 을 이용하여 입력 영상에서의 절대적 중심 위치 (${}^i ecp_{i,j}$: Estimated Center Point)를 다음 식 (8) 및 (9)와 같이 정의한다.

$${}^x ecp_{i,j} = X_{pos}(f_{in,j}) + \cos({}^i \theta_{in,j}) d_{in,j} \quad (8)$$

$${}^y ecp_{i,j} = Y_{pos}(f_{in,j}) + \sin({}^i \theta_{in,j}) d_{in,j} \quad (9)$$

최종적으로 추정된 절대적 중심위치 ${}^x ecp_{i,j}, {}^y ecp_{i,j}$ 을 이용하여 CM_i 을 다음 식 (10)과 같이 생성한다.

$$CM_i(a,b) = \sum_{j=1, \text{ selected } f_{in,j}}^{m_{in}} e^{-\frac{(a-{}^x ecp_{i,j})^2 + (b-{}^y ecp_{i,j})^2}{2 \times (avr_s \times margin)^2}} \quad (10)$$

여기서 a, b 는 화소의 위치를 나타낸다. 입력영상의 크기가 $M \times N$ 일 때, a, b 의 범위는 $1 \leq a \leq M, 1 \leq b \leq N$ 이다. CM_i 는 ${}^i ecp_{i,j}$ 가 집중해서 나타나는 지역의 화소 값이 큰 값을 가진다. 크기가 다른 같은 표적의 경우, 표적의 크기가 클수록 추정된 ${}^i ecp_{i,j}$ 의 위치가 다소 넓게 퍼지게 되고, $avr_s \times margin$ 은 이러한 차이를 CM_i 에 반영한다. 실험에서 $margin$ 은 10을 사용하였다.

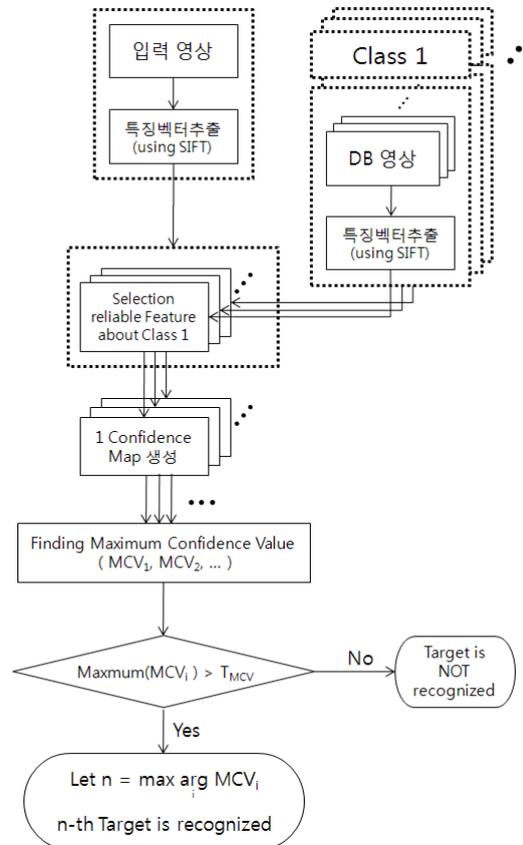


그림 3. 제안한 표적 분류 알고리즘.
Fig. 3. Proposed target classification algorithm.

각 클래스마다 CM_i 를 구하고 각각의 히스토그램의 최댓값을 MCV_i (Maximum Confidence Value)로 정의한다. MCV_i 의 값을 이용하여 식 (11)과 같이 표적을 분류한다. 전체적인 제안 알고리즘의 흐름도를 그림 3에 나타내었다.

$$Let \ n = \arg \max_i (MCV_i),$$

$$Result = \begin{cases} n\text{-th Class} & \text{if } MCV_n > T_{MCV} \\ \text{No Target} & \text{otherwise} \end{cases} \quad (11)$$

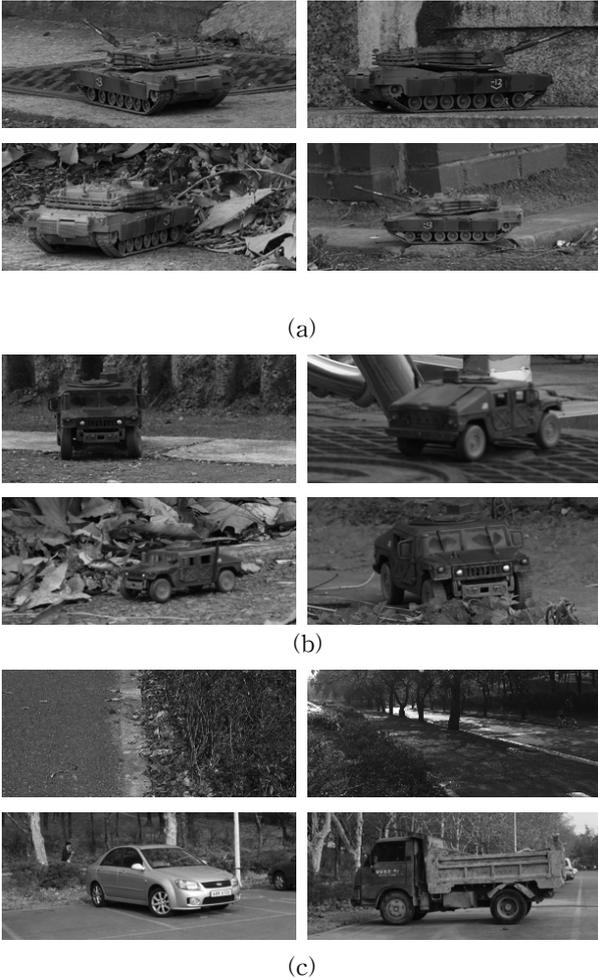


그림 4. 입력 영상의 예 : (a) 전차 영상, (b) 트럭 영상, (c) 배경 및 일반 차량 영상.

Fig. 4. Examples of input images : (a) tank images, (b) truck images, (c) backgrounds and other vehicles.

그림 5는 3가지 영상 그룹에 대한 MCV_{tank} , MCV_{truck} 값을 그래프로 나타내었다. 그림 5(a)의 36번 전차 영상은 MCV_{tank} 와 MCV_{truck} 의 값이 비슷하게 나타난다. 이는 전차와 트럭에서 비슷한 특징점이 나타나서가 아니라 전차에서 선택된 특징 벡터의 개수가 작기 때문이다. 그림 5(b)에서는 트럭 영상 그룹에서 오히려 MCV_{truck} 의 값이 MCV_{tank} 의 값보다 더 작게 나타나는 경우도 발생하지만 대부분의 입력 영상이 높은 MCV_{truck} 값을 가지는 것을 볼

수 있다. 그림 5(c)의 일반 배경 및 일반 차량의 영상 그룹에서는 두 값이 모두 작게 나타나고 이는 MCV 값이 표적 분류에 적절함을 보여준다.

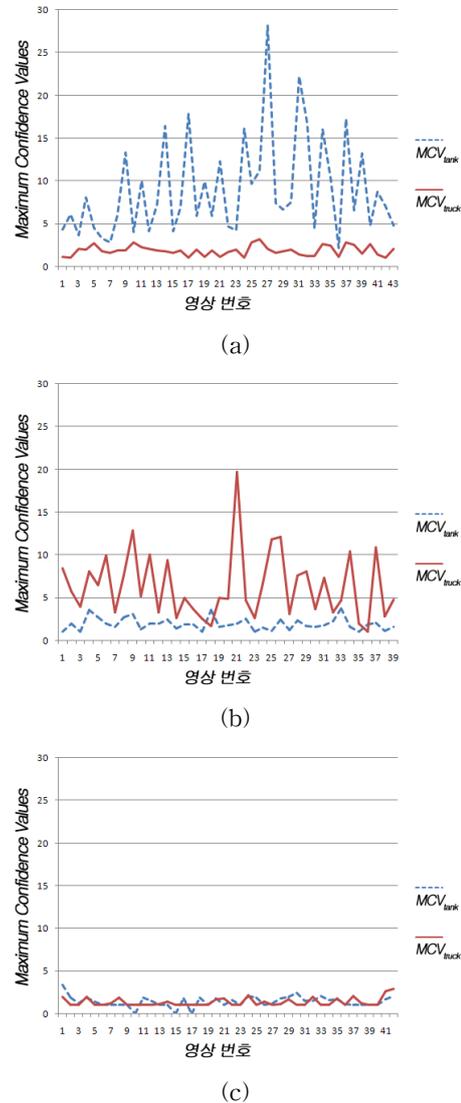


그림 5. 각 영상 그룹에 따른 MCV 그래프 비교 : (a) 전차 영상 그룹에 대한 MCV 그래프, (b) 트럭 영상 그룹에 대한 MCV 그래프, (c) 배경 및 일반 차량 영상 그룹에 대한 MCV 그래프.

Fig. 5. Comparison of MCV graphs for each image groups : (a) MCV graph for tank image group, (b) MCV graph for truck image group, (c) MCV graph for background and other vehicle group.

그림 6은 전차 그룹 영상과 트럭 그룹 영상에서 표적 내부의 정확히 매칭된 특징의 개수를 DB의 샘플링 간격에 따라 나타낸 그래프이다. 정확한 위치에서 발견된 특징의 개수는 MCV 값을 가지는 CM 의 픽셀 위치를 중심으로 $avr_s \times margin$ 을 반지름으로 하는 원 내부에 추정된 표적의 중심이 있는 특징 벡터의 개수이다. 샘플링 간격이 넓을수록 정확한 위치에서 발견된 특징의 개수가 확연히 줄어들어 가는 것을 볼 수 있다. 특히 10° 간격으로 샘플링 했을

때의 개수와 20° 간격으로 샘플링 했을 때의 개수의 차이가 20°와 30° 사이의 차이보다 상당히 크다는 것을 알 수 있다. 하지만 샘플링 간격이 좁아지면 실행 시간이 비례해서 증가하므로 실험에서는 10° 간격을 적절한 타협점(trade-off)으로 정하고 DB를 구성하였다.

회전 및 크기 변화에 따른 성능을 분석하기 위해 그림 7과 그림 8에 각각 회전과 크기에 따라 정확히 매칭된 특징의 개수의 변화를 그래프로 나타내었다. 실험에 사용된 입력 영상은 랜덤하게 뽑은 10개의 전자 영상이고 정확히 매칭된 특징의 개수는 이들의 평균값으로 정했다. 그림 7에서는 -30°~30° 사이를 3° 간격으로 회전 변화를 준 영상에서 실험 하였다. -15°~15° 회전된 표적의 영상에서 특징을 견실하게 찾음을 볼 수 있다. 그림 8은 영상의 크기만을 인위적으로 조절하여 실험한 결과를 나타낸다. 군사적 목적의 영상 내 표적은 보통 표적과 센서간의 거리가 멀기 때문에 표적의 크기는 크게 차이 나지 않기 때문에 50%~200%의 크기 변화만을 주고 실험 하였다. 70%~140% 차이에서 견실한 특징을 찾고 있음을 볼 수 있다.

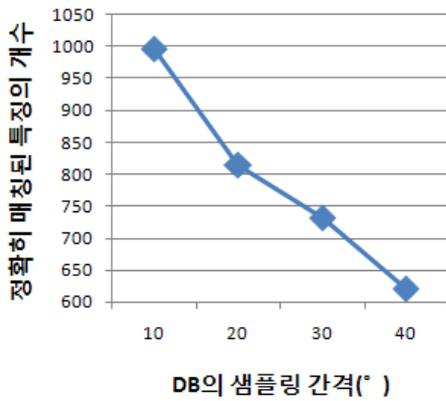


그림 6. DB의 샘플링 간격에 따른 정확히 매칭된 특징의 개수.

Fig. 6. The number of correctly matched features according to sampling unit for DB.

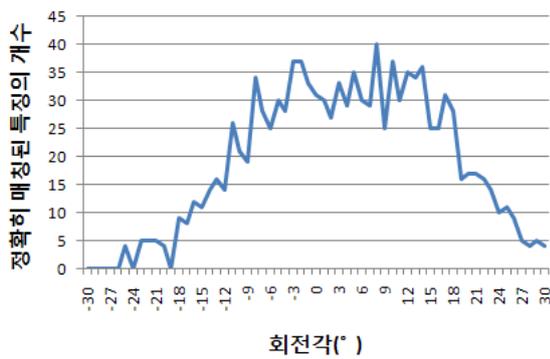


그림 7. 회전각에 따른 정확히 매칭된 특징의 개수.

Fig. 7. The number of correctly matched features according to rotation changes.

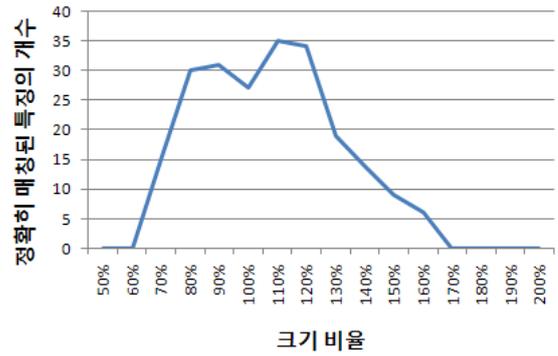


그림 8. 크기에 따른 정확히 매칭된 특징의 개수.

Fig. 8. The number of correctly matched features according to the scale changes.

표적 분류 성능을 측정함에 있어서 바르게 인식한 영상의 개수(TP)와 나머지 하나는 잘못 인식한 영상의 개수(FP)를 이용한다. 시스템의 성능을 향상시키기 위해서는 TP값은 최대화하고, FP값은 최소화해야 한다. 그러나 이 두 값은 서로 이율배반적인 관계에 있기 때문에 적절한 타협점(trade-off)을 선택해야 한다. 본 논문에서는 TP와 FP의 적절한 타협점을 찾기 위해 사용되는 *F-measure* [12]를 구하는 식은 다음 식 (12)와 같다.

$$F\text{-measure} = \frac{2 \times \text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}} \quad (12)$$

여기서 $\text{Recall} = TP/nP$, $\text{Precision} = TP/(TP+FP)$ 이고 nP 는 각 클래스에 속한 영상의 총 개수이다.

그림 9와 그림 10에 *Recall-Precision* 그래프와 T_{MCV} 에 따른 *F-measure* 그래프를 나타내었다. 여기서 T_{MCV} 가 2.5일 때 *F-measure* 값이 최대가 되므로, 인식을 실험에서의 T_{MCV} 값을 2.5로 정했다.

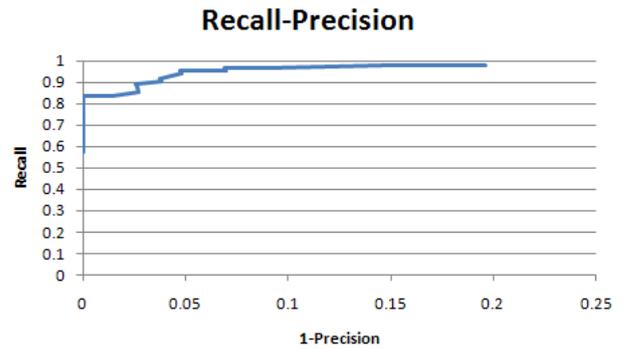


그림 9. Recall-Precision 그래프.

Fig. 9. Recall-Precision Graph.

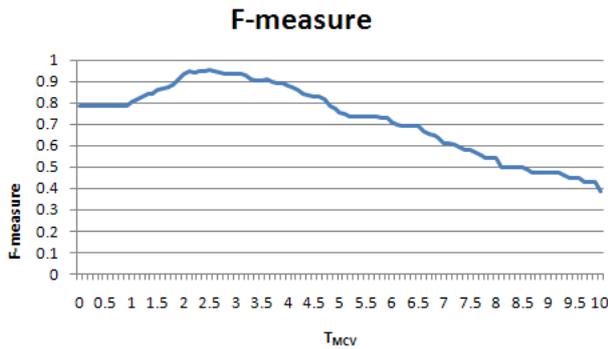


그림 10. T_{MCV} 에 따른 F -measure.

Fig. 10. F -measure for T_{MCV} .

제안 방법의 성능을 실험하기 위해 특징선별 과정을 거치지 않은 SIFT 특징벡터 사이의 유클리디안 거리를 이용한 인식률과 제안한 방법의 인식률을 표 1에 나타내었다. 입력 영상에 따라 인식률이 다르게 나타나는 것은 입력 영상에서 선택되는 특징점의 개수와 특징점의 서술자가 다르기 때문이다. 무인 감시를 위한 표적 분류 시스템은 실시간으로 처리되므로 실행 시간은 중요한 요소가 된다. 평균 실행 시간을 표 1에서 전체 영상에서의 인식률에 같이 나타내었다.

표 1. SIFT와 제안한 분류 방법의 인식률

Table 1. Recognition rates of SIFT and proposed classification method

입력영상 \ 분류방법	SIFT	제안 방법
전차영상	93.3 %	97.8 %
트럭영상	84.6 %	92.3 %
일반배경 및 일반차량 영상	90.5 %	92.9 %
전체 영상 (평균 실행시간)	89.7 % (0.43 s)	94.4 % (0.55 s)

5. 결론

CCD 센서로부터 획득된 영상은 계절 및 온도에 의한 제약이 크지 않은 고해상도 영상이므로, 적외선 영상과 더불어 자동 인식 시스템의 성능을 극대화 할 수 있다. 하지만 군사적 목적의 CCD 영상 내 표적은 복잡한 배경을 가지므로 배경과 표적의 특징이 비슷한 부분이 발생할 수 있다. 본 논문에서는 이러한 입력 영상의 특성을 고려하여 지역적 불변 특징 벡터를 선택적으로 활용함으로써 복잡한 환경에서도 표적을 효과적으로 분류하는 방법을 제안 하였다. 표적의 회전, 크기, 이동 변화에 강인한 SIFT 특징벡터를 이용하여 표적의 중심 위치를 나타내는 CM을 생성하고 이를 이용하여 표적을 분류 하였다. 표적의 자세 변화에 대응하기 위해 다양한 각도에서 획득된 입력 영상을 이용 하였고, 각 영상 그룹의 MCV값을 비교한 결과 안정된 척도임을 확

인 하였다. DB의 샘플링 간격에 따른 성능 비교에서 20° 이상의 샘플링 간격의 실험에서는 정확히 매칭된 특징의 수가 급격히 줄어드는 것을 확인하였고, 실험에 사용된 영상에서는 10° 간격으로 DB를 구성하는 것이 적절함을 보였다. 입력 영상의 크기와 회전의 변화에 따른 알고리즘의 성능을 살펴본 결과 크기와 회전이 크게 변하면 성능이 크게 나빠짐을 알 수 있었다. 하지만 표적은 기동 차량이므로 크기와 회전의 변화가 큰 영상을 입력 영상에서 제외 시켰다. 특징선별 과정을 거치지 않은 SIFT 특징벡터 사이의 유클리디안 거리를 이용한 인식률과 제안 알고리즘의 인식률 비교를 통해 제안한 표적 분류 방법이 우수한 성능을 보임을 증명하였다.

참 고 문 헌

- [1] B. Bhanu, "Automatic target recognition: state of the art survey," *IEEE Trans. Aerosp. Electron.Syst.* Vol. 22, no. 4, pp. 364-379, 1986.
- [2] S. Belongie, J. Malik, and J. Puzicha, "Shape Matching and Object Recognition Using Shape Contexts," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 24, no. 4, pp. 509-522, 2002.
- [3] S. G. Sun and H. W. Park, "Invariant feature extraction based on radial and distance function for automatic target recognition," *Proc. IEEE Int. Conf. Image Processing*, Vol. 3, pp. 345-348, 2002.
- [4] D. Zhang and G. Lu, "Review of shape representation and description techniques," *Pattern Recognition*, Vol. 37, pp. 1-19, 2004.
- [5] K. Mikolaiczuk and C. Schmid, "A performance evaluation of local descriptors," *IEEE Tran. on Pattern Analysis and Machine Intelligence*, Vol. 27, no. 10, 2005.
- [6] D. G. Lowe, "Object Recognition from Local Scale-Invariant Features," *Proc. Seventh IEEE International Conf. Computer Vision*, Vol. 2, pp. 1150-1157, 1999.
- [7] K. Mikolaiczuk and C. Schmid, "An Affine Invariant Interest Point Detector," *Proc. Seventh European Conf. Computer Vision*, pp. 128-142, 2002.
- [8] K. Mikolaiczuk and C. Schmid, "Scale and Affine Invariant Interest Point Detectors," *Int. J. Computer Vision*, Vol. 60, no. 1, pp. 63-86, 2004.
- [9] Y. Ke and R. Sukthankar, "PCA-SIFT: A More Distinctive Representation for Local Image Descriptors," *Proc. Conf. Computer Vision and Pattern Recognition*, Vol. 2, pp. 511-517, 2004.
- [10] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," *International Journal of Computer Vision*, Vol. 60, no. 2, pp. 91-110, 2004.
- [11] S. M. Pizer, E. P. Amburn, J. D. Austin, R.

Cromartie, A. Geselowitz, T. Greer, B. T. H. Romeny, and J. B. Zimmerman, "Adaptive histogram equalization and its variations," *Computer Vision, Graphics, and Image Processing*, Vol. 39, no. 3, pp. 355-368, 1987.

[12] S. Agarwal, A. Awan, and D. Roth, "Learning to Detect Objects in Images via a Sparse, Part-Based Representation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 26, no. 11, pp. 1475-1490, 2004.

저 자 소 개



이희열(Hee-Yul Lee)

2005년 : 경북대학교 수학과 졸업
2007년 : 경북대학교 수학과 석사 졸업
2008년 ~ 현재 : 경북대학교 전자공학과 박사 과정

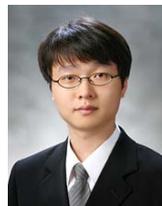
관심분야 : ATR 시스템, 신경 회로망
Phone : 010-2511-5608
E-mail : hy_lee@ee.knu.ac.kr



김종환(Jong-Hwan Kim)

2007년 : 경북대학교 전자전기컴퓨터 공학부 졸업
2007년 ~ 현재 : 경북대학교 전자공학과 석사과정

관심분야 : ATR 시스템, 신경회로망
Phone : 010-9389-8567
E-mail : kimjonghwan@ee.knu.ac.kr



김세윤(Se-Yun Kim)

2005년 : 경북대학교 전자전기컴퓨터 공학부 졸업
2007년 : 경북대학교 전자공학과 석사 졸업
2007년 ~ 현재 : 경북대학교 전자공학과 박사 과정

관심분야 : Machine vision, 패턴 인식
Phone : 010-8573-5577
E-mail : sykim@ee.knu.ac.kr



최병재(Byung-Jae Choi)

1987년 : 경북대학교 전자공학과 공학사
1989년 : 한국과학기술원 원자력공학과 공학석사
1998년 : 한국과학기술원 전기전자공학과 공학박사
1999년 ~ 현재 : 대구대학교 전자공학부 교수

관심분야 : 지능시스템, 인공지능 이론 및 응용, 마이크로프로세서 응용
Phone : 053-850-6635
Fax : 053-850-6619
E-mail : bjchoi@daegu.ac.kr



문상호(Sang-Ho Moon)

1982년 : 경북대학교 전자공학과 공학사
1984년 : 경북대학교 전자공학과 공학석사
1998년 : 경상대학교 전자계산학과 공학박사
1995년 ~ 현재 : 영남이공대학 모바일과 교수

관심분야 : 컴퓨터그래픽스, 멀티미디어
Phone : 053-650-9653
E-mail : shmoon@ync.ac.kr



박길흠(Kil-Houm Park)

1982년 : 경북대학교 전자공학과 공학사
1984년 : 한국과학기술원 전기전자공학과 공학석사
1990년 : 한국과학기술원 전기전자공학과 공학박사
1999년 ~ 현재 : 경북대학교 전자전기컴퓨터 공학부 교수

관심분야 : 영상신호처리, 패턴인식, 영상압축
Phone : 053-950-5549
Fax : 053-950-5505
E-mail : khpark@ee.knu.ac.kr