

논문 2012-49CI-2-13

영상 분류를 위한 분류기 통합모델

(Classifier Integration Model for Image Classification)

박 동 철*

(Dong-Chul Park)

요 약

영상 분류를 위한 다단계 특성벡터 기반의 분류기 모델(Partitioned Feature-based Classification Model with Expertise Table: PFC-ET)의 성능을 더욱 향상시킨 진보된 형태의 분류기 통합모델 (Classifier Integration Model: CIM)이 본 논문에서 제안되었다. CIM은 PFC-ET과 같이 주어진 데이터에서 추출된 전체의 특성벡터를 연결하여 이용하지 않고, 같은 성질의 특성벡터들끼리 모아서, 각각의 국지적 학습기를 통하여 분류에 이용한다. PFC-ET에서 분류판단 확률행렬에 의한 오류를 최소화하기 위해 국지적 분류기로 사용되는 군집화 알고리즘의 멤버 비율을 사용하여 최종적인 분류의 정확도를 높이는 방안을 제안한다. 제안된 CIM의 성능을 검증하기 위하여, Caltech 데이터에 대한 일반적인 영상 분류와 6 클래스 위성 영상 분류 문제에 대한 실험을 진행하였다. 제안된 CIM은 기존의 PFC 와 PFC-ET 모델과 비교한 실험에서 분류 정확도와 후처리 문제의 복잡성 면에서 향상된 성능을 보여주었다

Abstract

An advanced form of the Partitioned Feature-based Classifier with Expertise Table(PFC-ET) is proposed in this paper. As is the case with the PFC-ET, the proposed classifier model, called Classifier Integration Model(CIM), does not use the entire feature vectors extracted from the original data in a concatenated form to classify each datum, but rather uses groups of features related to each feature vector separately. The proposed CIM utilizes a proportion of selected cluster members instead of the expertise table in PFC-ET to minimize the error in confusion table. The proposed CIM is applied to the classification problem on two data sets, Caltech data set and collected terrain data sets. When compared with PFC model and PFC-ET model. the proposed CIM shows improvements in terms of classification accuracy and post processing efforts.

Keywords : classifier, image classification, clustering, neural networks, feature vector

I. 서 론

영상의 수집과 처리를 빠르게 할 수 있는 하드웨어의 발달에 따라 영상 처리와 분류에 관한 연구는 지속적으로 발달해 왔다^[1~3]. 그 중 수집된 데이터로부터 각 특징들을 추출하여, 그 데이터를 대표할 수 있는 특징벡터를 이용하는 방법은 영상자료를 효율적으로 관리하

며, 연산량을 줄이는 방법으로 패턴인식 분야에서 사용된 가장 기본적인 데이터처리 방법 중 하나이다. 한편, 영상은 그 자체로 색상, 질감, 주파수특성 등 모든 특징들을 포함하고 있으며, 그 중 위성영상은 여러 목적물을 포함하고 있어 하나의 특징만을 이용하여 분류나 인식을 하기에는 많은 어려움이 있다. 여러 가지 방법들을 통해 추출된 다양한 특징벡터들을 모두 포함하면서, 각 특성요소를 효과적으로 분류기에 이용하는 PFC^[4]나 PFC-ET^[5~6]등의 분류모델이 제안되었다. 이러한 분류 모델은 다양한 특징벡터를 그에 각각 대응하는 국지적 분류기에 사용하여, 그 결과를 통합함으로써 서로 다른 특징벡터들을 효율적으로 이용할 수 있는 방안으로 기존의 방식에 비해 좋은 성능을 보여주었다. 그러나

* 정희원-교신저자, 명지대학교 전자공학과
(Dept. of Electronics Eng., Myong Ji University,)
※ 이 논문은 2010년 정부(교육과학기술부)의 재원으로
한국연구재단의 지원을 받아 수행된 연구임
(2010-0009655).
접수일자: 2011년2월16일, 수정완료일: 2012년3월5일

PFC는 국지적 분류기의 전체 분류정확도에 기반하기 때문에 어떤 특징벡터가 특정범주의 데이터를 잘 분류하더라도 전체적인 분류정확도가 낮으면 통합분류기에 제대로 반영되지 않는 문제를 가지고 있다. 이를 보완하기 위해 개발된 PFC-ET은 각 특징벡터에 대해 분류판단행렬을 작성하여 세밀한 분류특성을 사용함으로써 보다 좋은 분류정확도를 보여주었다. 하지만 분류판단행렬을 작성하는 후처리가 필요하고, 각 군집이 각 범주를 제대로 대표하는 이상적인 분류가 만족되지 않을 경우 어떤 범주를 대표하는 군집이 누락될 수 있는 문제가 발생한다. 본 논문에서는 군집화 알고리즘의 학습과정에서 자연스럽게 발생하는 군집의 소속멤버의 비율을 국지적 분류기의 분류판단 행렬로 사용하여 특징벡터의 분류특성을 이용하고 다른 후처리가 필요 없이 구현할 수 있는 분류기모델을 제안하고, 제안된 모델을 Caltech 영상 데이터와 실제 위성영상 데이터의 분류에 적용하여 그 성능을 검증한다.

본 논문의 II장에서는 기존의 분류모델과 제안된 분류모델인 CIM에 대해 서술하고, III장에서는 국지적 분류기로 사용된 중심신경망^[7]과 기존의 중심신경망에서 유사도를 측정하기 위해 사용된 χ^2 거리를 사용하는 중심신경망^[8]에 대해 요약하고, IV장에서는 영상분류에서의 효율성을 검증하기 위해 Caltech-101 DB와 위성영상에 대한 분류 성능을 검증하는 실험을 수행하고, V장은 본 논문의 결론이다.

II. 다단계 특징벡터 기반의 분류기 모델들

2.1 Partitioned Feature-based Classifier 모델

PFC 모델^[4]은 각 특징벡터를 이용해 국지적 학습기에서 각각 학습시키고, 학습데이터에 대해 각 특징벡터에 의한 국지적 정확도를 산출하여 기여도를 계산한다. 즉, 주어진 데이터 \vec{x} 에 대하여 서로 다른 N 개의 특징추출기에 의해 추출한 특징벡터 \vec{f} 는 같은 특성을 가지 소그룹 특징벡터 \vec{f}_i ($i = 1, 2, \dots, N$)로 나누어진다. 학습과정에서는 각각의 특징벡터 \vec{f}_i 를 이용하여 N 개의 국지적 분류기 C_i 를 독립적으로 구성하게 된다. 또한, 각각의 국지적 분류기 C_i 에 학습에 사용하지 않은 검증데이터를 이용하여, 국지적 분류기 C_i 의 분류정확도 α_i 를 구하며, N 개의 국지적 분류기의 전체 분류기에

대한 분류기여도 ω_i 를 다음의 식에 의하여 정의한다.

$$\omega_i = \alpha_i / \sum_{j=1}^N \alpha_j \quad (1)$$

주어진 데이터 \vec{x} 에 대해, 학습된 국지적 분류기, $\{C_1, C_2, \dots, C_N\}$, 각각의 학습된 분류기의 기여도, $\{\omega_1, \omega_2, \dots, \omega_N\}$,가 주어져 있을 때, 데이터 \vec{x} 를 M 개의 클래스 중 하나의 클래스에 속하는 분류의 문제가 있다고 가정하면, 주어진 데이터 \vec{x} 에서 추출한 \vec{f}_i 가 대응하는 국지적 분류기 C_i 를 통과하면, 데이터 \vec{x} 와 M 개의 군집과의 거리는 다음의 식으로 표현된다.

$$\{d_{i1}(\vec{x}), d_{i2}(\vec{x}), \dots, d_{iM}(\vec{x})\}, i = 1, 2, \dots, N \quad (2)$$

한편, 각각의 국지적 분류기의 기여도를 고려하여, \vec{x} 와 각 군집과의 거리를 다음의 식으로 구한다.

$$d_i(\vec{x}) = \sum_{j=1}^M d_{ji}(\vec{x}) / \omega_j, i = 1, 2, \dots, M \quad (3)$$

결과적으로, \vec{x} 에 대한 분류 결과는 가장 가까운 거리를 나타내는 군집의 클래스로 구해진다^[7].

2.2 Expertise Table 을 가지는 PFC 모델

PFC-ET 모델^[5-6]은 국지적 분류기 C_i 가 주어진 데이터에 대해 분류를 j 로 판단했을 때 그 국지적 분류기가 이전에 어떤 분류 판단을 내렸는가를 고려해서 그 판단의 기여도를 측정하는 방식의 분류기 모델이다. 즉, 각각의 분류기에 다음과 같은 분류판단 확률 행렬을 가지고 있다고 하면, 여기서 P_{ij}^k 는 k 번째 국지적 분류기가 $Class i$ 의 데이터를 $Class j$ 로 판단하여 분류했던 확률이다. 다음의 식 (4)의 분류판단 확률 행렬은 주어진 학습데이터를 통해 구해진 것이다.

$$\begin{bmatrix} P_{11}^k & P_{12}^k & \dots & P_{1N}^k \\ P_{21}^k & P_{22}^k & \dots & P_{2N}^k \\ \vdots & & \ddots & \\ P_{N1}^k & \dots & P_{NN}^k \end{bmatrix}, \sum_{j=1}^N P_{ij}^k = 1 \quad (4)$$

이 경우, 기존의 다단계 분류기는 k 번째 국지적 분류기의 분류정확도를 다음의 형태로 구한 것이다. 즉,

$$\alpha_k = \frac{\sum_{i=1}^N P_{ii}^k}{\sum_{i=1}^N \sum_{j=1}^N P_{ij}^k} \quad (5)$$

위의 분류판단 확률 행렬을 최적으로 이용하여, 각 국지적 분류기의 판단 결과에 대한 최적의 분류정확도를 구하여 이용하는 분류기이다^[5-6].

2.3 Classifier Integration 모델

본 논문에서 제안하는 통합분류모델, CIM,은 국지적 분류기의 판단결과를 PFC보다 세밀하게 적용하여 좋은 결과를 얻는다. 그러나, 국지적 분류기의 판단결과를 정리하여 각 군집에 군집번호를 부여하고 분류 판단 확률행렬을 작성해야하는 번거로움이 있다. 군집이 각 클래스를 제대로 대표하지 못하여 어떤 클래스를 대표하는 군집이 누락될 경우 전체적인 분류결과에 매우 좋지 않은 영향을 주게 된다. 또한, 분류 판단 확률행렬을 작성할 때 최적의 분류도를 보여주는 조합을 찾아 각 군집을 라벨링하는 문제가 발생한다. 따라서, 본 논문에서는 명확하지 않은 후처리를 배제하고, 부정확한 후처리에 의한 전체 분류정확도의 저하를 방지하기위해 학습 단계에서 자연스럽게 얻어지는 각 군집이 가지고 있는 군집 멤버들의 구성비를 이용하여 분류결과표를 대체하는 새로운 다단계 분류 모델을 제안한다. 제안되는 통합분류기 모델도 PFC나 PFC-ET 모델들과 동일하게 특징벡터들의 소집합에 대해 그에 상응하는 N 개의 국지적 분류기를 가지게 된다. 그 후 각 국지적 분류기는 입력되는 학습데이터에 대해 가장 가까운 군집을 선택하게 되며, 선택된 군집이 각 클래스의 데이터를 얼마나 포함하고 있는지가 국지적 분류기의 가중치로 사용된다. 즉, 국지적 분류기 k 에서 입력 실험 벡터 \vec{x} 가 군집 i 와 가장 가깝다면, 가중치 $w_k(x)$ 는 i 번째 군집이

각 클래스의 데이터를 얼마나 포함하고 있는지에 대한 확률이 된다.

$$w_k(x) = [M_{i1}^k, M_{i2}^k, \dots, M_{iN}^k] \quad (6)$$

여기서, $w_k(x)$ 는 입력 테스트 벡터 x 에 대한 k 번째 국지적 분류기의 가중치이고, M_{ij}^k 는 k 번째 국지적 분류기에서 선택된 i 번째 군집이 포함하고 있는 클래스 j 의 멤버수이다.

각 국지적 분류기의 모든 판단 결과를 모아 그중 가장 큰 확률을 보여주는 클래스가 입력 실험 벡터 \vec{x} 의 클래스가 된다. 이는 다음의 수식으로 표현된다. 즉,

$$\alpha(j) = \sum_{k=1}^N M_{ij}^k, \quad i = \arg \min(d_i) \quad (7)$$

여기서, $\alpha(j)$ 는 j 클래스에 대한 분류가중치이고, 분류가중치는 각 국지적 분류기 k 에서 선택된 클러스터 i 의 멤버들중 같은 클래스 j 의 누적합으로 구해진다

$$Class(\vec{x}) = \arg \max_j \alpha(j), \quad \forall j = 1, 2, \dots, N. \quad (8)$$

결과적으로 입력벡터 \vec{x} 는 가장 큰 분류가중치를 가지는 $\alpha(j)$ 에 의해 j 클래스로 분류된다. 즉, 이로 인해 분류판단 확률행렬을 작성하는 후처리과정에서 발생하는 대표 군집의 누락을 방지하고, 검증데이터가 어느 클래스에 속할 확률을 가지고 있는지 더욱 세밀하게 적용할 수 있다.

III. 지역분류기로 사용된 군집화 알고리즘

3.1 Centroid Neural Network(CNN)

중심신경망^[7]은 K-means 나 Self-Organizing Map (SOM)과 같은 기존 알고리즘이 매 학습마다 연결강도를 수정하는 것과 달리, 승자와 패자의 연결강도를 각각 설정하여 현재와 이전 학습에서 뉴런의 상태에 대한 정보를 이용하여, 가중치를 변화시킨다.

CNN의 가중치 갱신식은 다음과 같으며, i 는 승자 뉴런, j 는 패자뉴런을 각각 나타낸다. N_i 와 N_j 는 각각 승자뉴런과 패자뉴런에 포함된 데이터의 수이다.

$$w_i(n+1) = w_i(n) + \frac{1}{N_i+1}[x(n) - w_i(n)] \quad (9)$$

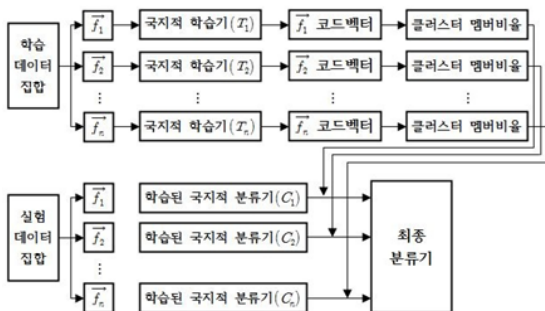


그림 1. 통합분류기 모델

Fig. 1. Classifier Integration Model.

$$w_j(n+1) = w_j(n) - \frac{1}{N_j-1} [x(n) - w_j(n)] \quad (10)$$

중심 신경망은 k-means 나 SOM 과 같은 기존의 경쟁 알고리즘과 비교하여 몇 가지 장점을 갖는데, 사전에 학습계수나 전체 학습 반복수등 동작을 위한 변수를 설정 할 필요가 없으며, 더불어 기존의 군집화 알고리즘에서 문제점으로 지적되었던 초기 연결강도 설정의 문제까지 효과적으로 해결함으로써 자동적으로 준최적의 군집화 결과를 안정적으로 도출하는 장점이 있다^[7].

3.2 χ^2 -거리함수의 중심신경망

기존의 CNN은 대표적인 군집화문제에 적용되어 많은 좋은 결과를 도출 했지만, 히스토그램으로 특징벡터가 주어지는 등의 고차원 특징벡터에 대한 군집화문제에 적용하는데 있어 적당하지 않을 수도 있다. 두 히스토그램의 유사도를 효과적으로 측정하기 위해, 다음의 χ^2 거리측정방법이 적용되었다^[8].

$$\chi^2(M, S) = \sum_{i=1}^Q \frac{(M_i - S_i)}{S_i} \quad (11)$$

$$J = \sum_{k=1}^Q \sum_{i=1}^N \frac{(w_k - x_i(k))^2}{x_i^2}, \quad x_i(k) \in \text{Group } k \quad (12)$$

여기서 M 과 S 는 각각 모델과 샘플 히스토그램이고, Q 는 히스토그램의 차원을 나타낸다.

새로운 거리함수를 이용하는 CNN- χ^2 의 목적함수의 새로운 정의에 의해, 새로운 목적함수를 만족시키는 가중치의 갱신식 또한 다음과 같이 수정된다^[8].

$$\frac{1}{w_j(n+1)} = \frac{1}{w_j(n)} + \frac{1}{N_j+1} \left(\frac{1}{x(n)} - \frac{1}{w_j(n)} \right) \quad (13)$$

$$\frac{1}{w_i(n+1)} = \frac{1}{w_i(n)} - \frac{1}{N_i-1} \left(\frac{1}{x(n)} - \frac{1}{w_i(n)} \right) \quad (14)$$

IV. 실험 및 결과

II장에서 살펴본 기존의 알고리즘들과 이 논문에서 제안된 알고리즘의 비교실험을 위해 총 4가지의 특징추출 방법을 사용하였다. 사용된 특징은 색상 정보를 표현하기 위한 200차원 값의 HSV^[9], 주파수 정보를 표현

하기 위한 64차원 값의 DCT 계수^[10], 질감 정보를 표현하기 위한 59차원 값의 LBP 히스토그램^[11], 독립성분 분석에 의거한 50차원 값의 희소코딩 (sparse coding) 계수^[12]를 특징으로 사용하였다.

4.1 Caltech Database에 대한 분류

Caltech-101 데이터^[13]는 2003년 California Institute of Technology의 컴퓨터 비전 연구소에서 F. Li등에 의해 수집되었는데, 총 9146개의 정지영상을 포함하고있으며, 분류, 인식, 범주화 문제들에 대한 알고리즘의 성능을 실험하기위해 널리 사용되었다^[14]. 본 논문에서는 영상 분류를 위해 Airplanes, Cars, Faces, Leopard 의 4가지 범주의 데이터를 사용하였고, 각 범주는 모두 200장의 정지영상으로 구성되어 총 800장의 정지영상을 이용하여 영상분류 실험을 진행하였다. 모든 데이터를 테스트 데이터로 적용하기위해 각 범주마다 무작위로 선택된 180장의 데이터를 이용해 학습하고, 나머지 20장의 데이터를 테스트 데이터로 사용하는 방식으로 학습-테스트 데이터 10개 집합을 실험에 사용하였다. 그림

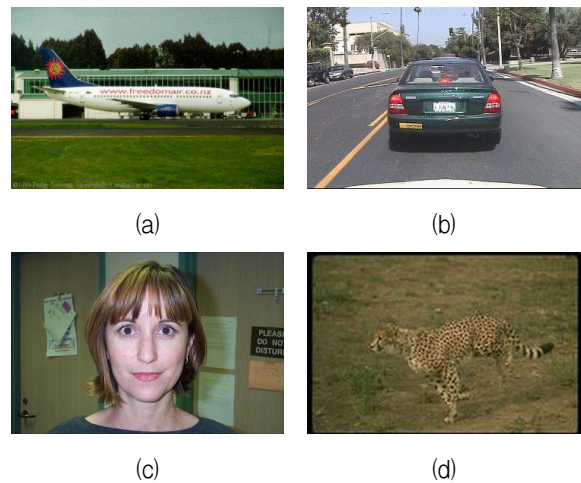


그림 2. Caltech 데이터의 예 (a)비행기 (b)자동차 (c)사람얼굴 (d)표범

Fig. 2. Example of Caltech database. (a) airplanes (b) cars (c) faces (d) leopards.

표. 1. CIM의 Caltech 데이터에 대한 여러 특징벡터 분류결과(%).

Table 1. CIM's Classification Accuracy (%) on Caltech Database using various features.

	DCT	HSV	LBP	SC	Overall
CNN	50.14	67.02	59.5	63.27	59.98
CNN- χ^2	48.93	70.55	64.77	60.59	61.21

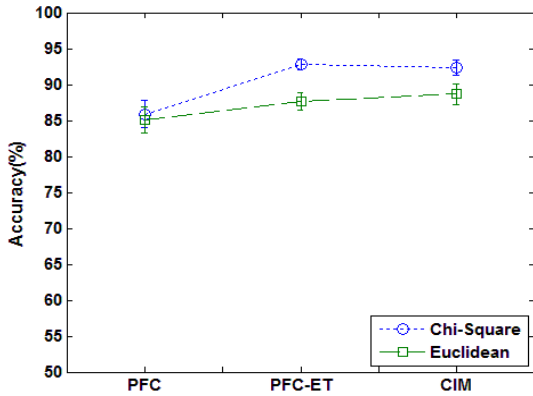


그림 3. Caltech 데이터의 분류모델 분류 결과
Fig. 3. Classification Results for Caltech database.

2는 각 범주에 포함된 데이터의 예이다. 다중 분류모델들의 분류정확도가 기존의 단일 분류 모델에 비해 얼마나 좋은 결과를 보여주는지 비교하기 위해 단일 특징벡터를 사용하여 실험을 진행하였다. 그 결과는 표 1에 요약되었다. CNN 알고리즘은 DCT 특징이 50.14%로 가장 낮은 분류결과를 보여주었고, HSV특징이 67.02%로 가장 좋은 결과를 보여주었다. CNN- χ^2 의 경우 DCT의 분류결과가 48.93%으로, SC의 결과가 60.59%로 기존의 CNN보다 다소 좋지 않은 결과를 보여주었으나, 모든 특징에 대한 평균은 59.98%에서 61.21%로 전체적으로 더 좋은 결과를 보여주었다.

제안된 분류 모델의 효용성을 검증하기 위하여 위의 단일분류기들을 국지적 분류기로 이용하여 모든 특징벡터들을 다중 분류모델 PFC, PFC-ET 그리고 제안된 CIM에 적용하여 분류정확도를 비교하였다. 그림 3에 요약된 결과에서 보듯이, 단일 특징 분류결과와 평균이 위와 같이 60% 주변을 기록하는 반면 PFC는 85%대의 좋은 결과를 보여준다. 하지만 PFC-ET이나 CIM은 80% 후반에서 90%를 넘기는 보다 정확한 결과를 보여주고 있으며, 표준편차 또한 PFC보다 작은 수치를 보여주어 안정적인 분류결과를 제공함을 알 수 있다. 기존의 CNN을 국지적 분류기로 사용한 실험에서는 PFC-ET가 87.7%, CIM이 88.65%로 CIM이 좀 더 좋은 결과를 보여주었고, CNN- χ^2 을 국지적 분류기로 사용했을 때 PFC-ET이 92.8%, CIM이 92.32%로 CIM이 약간 낮은 분류결과를 보여주었지만 국지적 분류기의 분류결과를 수집하여 분류판단행렬을 작성하는 후처리 과정이 없이도 CIM을 이용하여 거의 대등한 결과를 얻을 수 있음을 보여준다.

4.2 위성영상에 대한 분류

제안된 분류모델을 위성영상 데이터의 분류에 적용한 실제 분류결과를 제시함으로써 제안된 알고리즘의 유용성을 검증하였다. 위성영상 DB에서 목적에 부합하는 목적물의 검출을 위하여, 먼저 영상의 분류는 필수적이며 분류된 영상에서 목적물을 검출하는 과정이 필요하다. 예를 들어, 산악지대에 존재하는 10m 이상의 높이를 가지는 건물을 추출하려할 경우, 먼저 산악지대의 영상을 다른 지역의 영상으로부터 분류하는 것이 필요하다. 이 문제는 현재 한국연구재단의 지원으로 진행 중인 과제의 목적의 하나이다. 데이터는 Airport, Bridge, Harbor, Land, Pond 그리고 Urban등 6개 범주를 포함하고 있으며 512×512크기의 위성 정지 영상을 각 범주마다 100장씩 총 600장을 수집하였다. 그림 4는 위성 데이터의 예시이다. 위성 영상 분류실험 또한 10분 교차 검증방법에 따라 진행되었다.

그림 5와 표 2와 같이 단일 특징 벡터에 대한 분류결과에서 CNN을 국지적분류기로 이용한 분류결과와 평균은 51.53% 이었고, CNN- χ^2 를 이용한 분류결과와 평균은 56.61%로 Caltech 데이터의 실험에서와 같이 대부분의 특징 벡터에 대해 기존의 CNN보다 CNN- χ^2 이

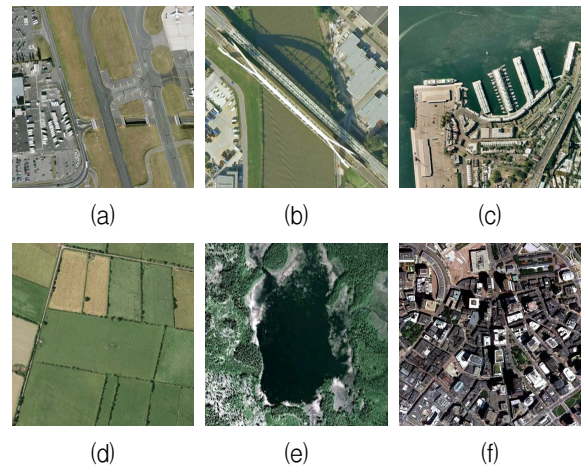


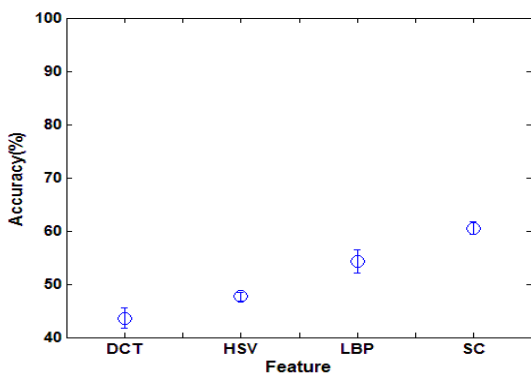
그림 4. 위성 영상 데이터의 예. (a) Airport (b) Bridge (c) Harbor (d) Land (e) Pond (f) Urban
Fig. 4. Example of Terrain database. (a) Airport (b) Bridge (c) Harbor (d) Land (e) Pond (f) Urban.

표 2. CIM의 범주별 분류결과
Table 2. CIM's Classification results for each category.

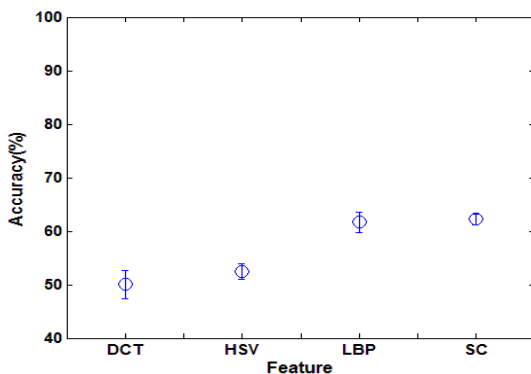
	Airp	Brid	Har	Land	Pond	Urb	Overall
CNN	48.02	59.5	54	64.44	56.67	26.57	51.53
CNN- χ^2	52.66	58.77	62.91	60.32	42.31	62.7	56.61

향상된 결과를 보여주었다. 전체적인 분류정확도는 비록 5.08%의 상승에 그쳤지만 표 2에서 Urban 범주에 대한 분류정확도가 26.57%에서 62.70%로 대폭 상승하여 자칫 무시될 수 있었던 범주의 데이터를 잘 분류함을 확인하였다. 이로 인해 CNN- χ^2 이 벡터 사이의 유사도를 잘 구분하여 보다 정확한 군집이 형성되게 함을 알 수 있다.

기존의 CNN을 국지적 분류기로 사용하여 다중 분류 모델에 적용한 실험 결과에서는 PFC가 55.83%로 Caltech 데이터를 사용한 실험에 비해 다소 낮은 폭의 성능 향상을 보여주었다. 이는 각 국지적 분류기 C_i 에 대한 분류기여도 w_i 가 혼동된 분류결과를 주는 국지적 분류기의 분류기여도가 더 높아서 발생하는 문제이며, 이는 CIM이 제안된 이유와 일치한다. PFC-ET의 학습이 완료된 후 LBP 특징벡터를 사용한 국지적 분류기를



(a)



(b)

그림 5. CIM의 위성영상 DB에 대한 여러 특징벡터에 대한 지역분류기의 분류결과. (a) CNN (b) CNN- χ^2

Fig. 5. CIM's Classification Results on Terrain database using various features.(a) CNN (b) CNN- χ^2 .

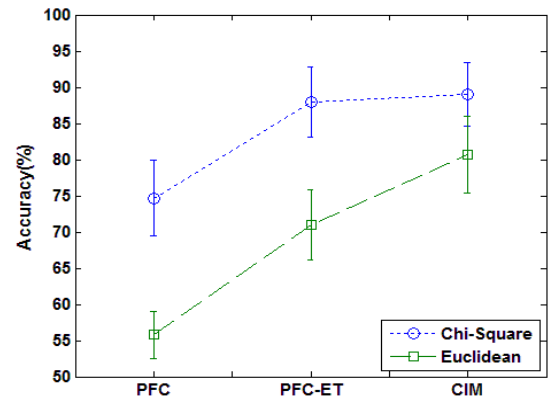


그림 6. 위성영상 DB에 대한 여러 분류모델 분류결과.
Fig. 6. Classification Results of various classifier models on Satellite database.

표 3. LBP의 분류판단행렬
Table 3. Confusion table of LBP.

	Airp	Brid	Harb	Land	Pond	Urb
Airp	0.67	0	0	0.33	0	0
Brid	0.21	0.25	0	0	0.54	0
Har	0	0	0.4	0.233	0.287	0.08
Land	0	0	0	0.83	0	0.17
Pond	0	0.28	0	0	0.72	0
Urb	0	0	0.61	0	0	0.39

통해 작성된 분류판단 확률행렬을 표 3에 제시하였다. 표 3에서 보듯 Urban 범주를 대표하는 군집6은 오히려 Harbor 범주를 대표하는 군집3에 비해 더 높은 가중치를 가지고 있지만, 전체적인 분류정확도를 최대로 만드는 조합을 만족하기 위해 Urban 범주를 대표하고 있다. 그에 반해 CIM은 학습된 군집에 범주의 의미를 부여하지 않고 선택된 군집에 속한 범주의 데이터 수에만 집중한다. 따라서 학습된 분류기에 대해 후처리로 인한 오류를 방지하여 PFC-ET보다 좋은 80.67%의 분류정확도를 보여주었다. CNN- χ^2 를 국지적 분류기로 사용한 실험에서 더욱 만족스런 결과를 얻을 수 있었는데, PFC가 74.67%의 분류정확도를, PFC-ET과 CIM이 각각 87.99%와 89.02%의 분류정확도를 보여 주었다. 그림 6에서는 CNN- χ^2 가 보다 정확한 군집을 형성함으로써 앞에서 설명했던 PFC-ET의 문제들이 발생되지 않아 PFC-ET의 분류결과가 매우 향상되었음을 유추 할 수 있다. 하지만 모든 분류문제에 대해 이상적인 군집결과를 얻을 수 있다는 기대를 할 수 없기 때문에 CIM이 제안되었다. 그림 6에서 보듯이 CNN- χ^2 을 이용하는

국지적 분류기의 성능향상에 의해 CIM은 89.02%의 매우 좋은 분류정확도를 보여주어 제안된 알고리즘의 유용성을 확인할 수 있다.

V. 결 론

본 논문에서는 효과적인 영상분류를 위하여 서로 다른 기준에 의해 추출된 특징들을 상호보완적으로 사용하는 새로운 다중 분류모델인 통합 분류모델을 제안하였다. 제안된 통합분류모델은 PFC-ET 모델에서 발생할 수 있는 명확하지 않은 후처리를 배제하고, 부정확한 후처리에 의한 전체 분류정확도의 저하를 방지하기 위해 학습단계에서 자연스럽게 얻어지는 각 군집이 가지고 있는 군집 멤버들의 구성비를 이용하여 분류결과표를 대체하는 새로운 다단계 분류 모델이다. 널리 이용되는 Caltech 데이터와 위성영상 데이터에 재한 분류 문제에 대한 실험을 통해 기존의 PFC나 PFC_ET보다 향상된 분류 정확도를 보여줌으로써 제안된 분류모델의 효율성을 증명하였다. 기존의 분류모델인 PFC와 PFC_ET가 분류정확도에서 단일 분류결과 보다 좋은 결과를 보여주었지만, PFC는 국지적 분류기의 분류결과를 세밀하게 적용하지 못하는 단점이 있었고, PFC_ET는 이상적인 군집화가 이루어지지 않았을 경우 잘못된 분류판단확률행렬을 생성함으로써 전체적인 분류결과에 악영향을 끼치게 되었다. 이를 극복하는 제안된 분류모델인 CIM은 보다 간단한 구현과 향상된 분류정확도를 통하여 그 효용성을 확인할 수 있었다.

참 고 문 헌

- [1] 이동훈, 김종화, 최홍문. 위성영상에서 도로 추출을 위한 히스토그램 기반 경계선 추출자. *전자공학회 논문지-SP*, 제44권 제5호, 28-34쪽, 2007.
- [2] Z. Wang, J. Yong. Texture Analysis and Classification With Linear Regression Model Based on Wavelet Transform. *IEEE Trans. Image Processing*, 8:1421-1430, 2008.
- [3] D.-C. Park, D.-M. Woo. Image Classification Using Gradient-Based Fuzzy c-Means with Divergence Measure. *Proc. of IJCNN*, 2521 - 2525, 2008.
- [4] D.-C. Park. Image classification using Partitioned-Feature based Classifier model, *Proc. of IEEE Int. Conf. on AICCSA*, 1-6, 2010.

- [5] 김재영, 박동철, 진보된 다단계 특징벡터 기반의 분류기 모델, *전자공학회논문지*, 제47권, CI편, 제3호, 36-41쪽, 2010.
- [6] D.-C. Park. Partitioned Feature-based Classifier model with Expertise Table. *Proc. of IEEE Int. Conf. on BIC-TA*, 737-742, 2010.
- [7] D. C. Park. Centroid Neural Network for Unsupervised Competitive Learning. *IEEE Trans. Neural Networks*, 11(2), 520 - 528, 2000.
- [8] V. Huong, D.-C. Park, Y. Lee. Centroid neural network for face recognition. *Proc. of IJCNN*, 1304-1309, 2009.
- [9] C. Novak, S. Shafer. Anatomy of a color histogram. *IEEE Trans. CVPR*, 599-605, 1992.
- [10] N. Ahmed, et al.. Discrete Cosine Transform. *IEEE Trans. Computer* 1, 90-93, 1974.
- [11] T. Ojala, M. Pietikäinen, D. Harwood. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions. *Proc. of ICPR*, 1, 582-585, 1994.
- [12] B. A. Olshausen, D. J. Field. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. *Nature*, 381, 607 - 609, 1996.
- [13] www.vision.caltech.edu/...Datasets/Caltech101/
- [14] A. Berg, et al.. Shape matching and object recognition using low distortion correspondences, *IEEE Trans. CVPR*, 1, 26-33, 2005.

저 자 소 개

박 동 철(정회원)-교신저자
대한전자공학회 논문지
제 48권 CI편 제 1호 참고